

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Darko Krmpotić

**ANALIZA INFORMACIJSKIH OBRAZACA
PROCESNIH SIGNALA POMOĆU
EKSPANDIRANE 1D CARNAPOVE
ENTROPIJE**

doktorska disertacija

Osijek, 2016.

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Darko Krmpotić

**ANALIZA INFORMACIJSKIH OBRAZACA
PROCESNIH SIGNALA POMOĆU
EKSPANDIRANE 1D CARNAPOVE
ENTROPIJE**

doktorska disertacija

Osijek, 2016.

Mentor: doc.dr.sc. Damir Blažević

Povjerenstvo za ocjenu doktorske disertacije

1. Dr.sc. Dražen Slišković, izvanredni profesor, znanstveni savjetnik, predsjednik, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
2. Dr.sc. Damir Blažević, docent, mentor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
3. Dr.sc. Bojan Jerbić, redoviti profesor, član, Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu

Povjerenstvo za obranu doktorske disertacije

1. Dr.sc. Dražen Slišković, izvanredni profesor, znanstveni savjetnik, predsjednik, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
2. Dr.sc. Damir Blažević, docent, mentor, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
3. Dr.sc. Bojan Jerbić, redoviti profesor, član, Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu
4. Dr.sc. Ratko Grbić, docent, član Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek
5. Dr.sc. Tomislav Keser, docent, član, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek

Broj doktorske disertacije: 57

Zahvala

Veliko hvala

- prof.dr.sc. Franji Joviću na svesrdnoj pomoći i suradnji tijekom izrade doktorske disertacije kao i objavljenih znanstvenih radova
- dr.sc. Alanu Joviću na suradnji tijekom izrade doktorske disertacije
- prof.dr.sc. Ninoslavu Slaveku na povjerenju i suradnji
- mentoru doc.dr.sc. Damiru Blaževiću na suradnji, sugestijama i pomoći
- doc.dr.sc. Emmanuelu Karlu Nyarko na podršci i vrijednim savjetima
- supruzi i kćerkama neizmjereno hvala na podršci, strpljenju i razumijevanju
- obitelji i prijateljima na zanimanju i ohrabrivanju

SADRŽAJ

Popis slika	VI
Popis tablica	VIII
Popis simbola	IX
1. UVOD – MOTIVACIJA I OKOLIŠ PROBLEMA.....	1
1.1. Informacijski podsustav proizvodnje i suvremena znanost.....	2
2. PROCESNI SIGNALI - OPIS PROIZVODNIH PROCESA I PROCESNIH SMETNJI	8
2.1. Poznavanje dinamike procesa detekcijom i otkrivanjem procesnih smetnji	8
2.2. Opća teorija pojave smetnji za Poissonovu razdiobu pojava smetnji i proizvoljno kodiran procesni obrazac.....	13
2.3. Detekcija vremenskih serija praćenjem dinamike procesnih obrazaca.....	14
2.4. Usporedba korištenja procesnih obrazaca pri Shannonovoj i Carnapovoj 1D neekspandiranoj i ekspandiranoj entropiji	16
3. OPĆI UVJETI ODRŽAVANJA PROCESNE PROIZVODNJE.....	22
3.1. Informacijski podsustav	23
3.2. Sustavski procesni obrasci i njihova dinamika	24
3.3. Podsustav upravljanja kvalitetom.....	26
3.3.1. Metode upravljanja kvalitetom	27
3.4. Materijalni podsustav	50
3.4.1. Jedinični proizvodni procesi	50
3.4.2. Porodice jediničnih procesa	53
3.4.3. Taksonomija jediničnih proizvodnih procesa, potporni postupci	55

3.4.4.	Procesni tokovi i integrirana proizvodnja.....	58
4.	KRITIKA POSTOJEĆIH RJEŠENJA SUSTAVA KVALITETE PROIZVODNJE I PRIPADNIH INFORMACIJSKO PROCESNIH OBRAZACA	59
4.1.	Metode osiguranja i kontrole kvalitete	59
4.2.	Pristup kontroli kvalitete temeljeno na informacijskom sustavu	62
5.	EKSPANDIRANA 1D CARNAPOVA ENTROPIJA	66
5.1.	Izračun abecedne entropije vremenski ograničenog procesnog obrasca	66
5.2.	Osobine abecedne entropije.....	70
5.3.	Teselacijska entropija informacijskih obrazaca kao model procesne dinamike kvalitete izlaznog proizvoda.....	72
5.3.1.	Tehnički problemi s informacijskim sadržajem signala	72
5.3.2.	Ekspanzija informacijskog sadržaja procesnog signala	73
5.3.3.	Opis postupka teselacijske entropije proširenog mjernog signala	73
5.3.3.1.	Abecedna entropija i njena primjena	73
5.3.3.2.	Primjena teselacijske entropije na kontrolu kvalitete šaržnog industrijskog procesa.....	81
5.3.4.	Detaljan opis primjera određivanja potencijalnog uzroka kvara na prešama Magnum	83
5.3.4.1.	Opis skupa mjernih podataka kontrole kvalitete	83
5.3.4.2.	Impaktogram za preše #9 i #10 Magnum.....	86
5.3.5.	Detaljan opis primjera određivanja potencijalnog uzroka na dvokanalnoj peći.	89
5.3.5.1.	Dvokanalna peć	89
5.3.5.2.	Podaci dvokanalne peći	90

5.3.5.3. Izrada impaktograma	92
5.3.5.4. Rezultati detaljnog istraživanja škarta impaktogramima po prešama uporabom signala s dvokanalne peći	93
6. ORGANIZACIJA I PROVEDBA DOBIVENIH REZULTATA NA POBOLJŠANJE EKONOMIČNOSTI PROIZVODNJE.....	96
6.1. Postojeće informacijske mjere i informacijski obrasci: opća konvergencija modela i stvarnog stanja proizvodnje.....	96
6.2. Kritika postojećih mjera informacije procesnih obrazaca	98
6.3. Reproducibilnost kvalitete proizvoda	99
6.4. Signali i kontrolni postupci u kontroli kvalitete keramičke proizvodnje.....	100
6.5. Signali kontrole kvalitete u proizvodnji keramike prešanjem	102
6.6. Model sustava upravljanja kvalitetom	106
7. RASPRAVA	109
7.1. Rasprava o proizvodnom procesu i pravodobnoj detekciji škarta.....	109
7.2. Rasprava o primjenjivosti postupka u proizvodnom procesu i ekonomičnosti provedbe	111
8. ZAKLJUČAK	115
LITERATURA	117
SAŽETAK	128
SUMMARY.....	129
ŽIVOTOPIS..	130
Dodaci A,B,C,D	131
Dodatak A.....	131

Dodatak B	151
Dodatak C:	164
C1. Postavka problema osposobljenosti i motiviranosti zaposlenika	164
C2. Postojeća stanja i rješenja pri motiviranosti zaposlenika	165
C3. Zatečeno stanje i organizacijska struktura.....	165
C3.1 Specifičnosti kvalitativnog istraživanja organizacija	166
Dodatak D Impaktogrami na prešama, entropije i interpretacije rezultata.....	174
D1. Impaktogrami na prešama	174
D2. Entropije na prešama 9 i 10.....	177
D3. Interpretacije rezultata	180
Dodatak E Analiza entropije signala kontrole kvalitete u KIO Keramika d.o.o	182

Popis slika

Slika 2.1.	Uzročno posljedični ili Ishikawa dijagram na proces zamrzavanja ribe [9].	12
Slika 2. 2.	Carnapova 1D entropija znaka 'b'; uočimo granice područja 'zauzimanja' označene sa $L+\Delta/2$, $L+3\Delta/2$, $L+5\Delta/2$ gdje je Δ korak delta modulacije pri aproksimaciji mjerenja.	19
Slika 2. 3.	Ekspanzija pet mjernih uzoraka znaka 'b' {+,+,+,-} sa svim međumjerenjima na niz {+++; ++0; ++;+}	19
Slika 2. 4.	Kumulacija obrazaca pri ternarnom kodiranju signala za 1,2,3,4, i 5 promjena signala	20
Slika 3.1.	Ishikawa dijagram – idejna zamisao	28
Slika 3.2.	Razine kvalitete: od kontrole kvalitete do TQM-a	47
Slika 3.3.	Model potpunog upravljanja kvalitetom [Funda, 2012]	49
Slika 3.4.	Jedinični proces: tijek informacije te materijala ili komponenti; resursni zahtjevi [NRC, 1995]	51
Slika 3.5.	Model jedinične procesne proizvodnje	52
Slika 3.6.	Porodice jediničnih procesa prema komponentama, materijalima i procesnim obradama [NRC 1995]	53
Slika 3.7.	Komponente jediničnog procesa i potporni postupci [Bakerjian, 1993], [NRC, 1995]	57
Slika 5.1.	Elementi izračuna 1D Carnapove entropije	75
Slika 5.2.	Potpuna ekspanzija četiriju mjerenja M1,M2, M3 i M4, prikazana s osnovnim mjenjem M1 i šest mjernih razlika	75
Slika 5.3.	Histogram signala QC za prešu #9 (lijevo) i prešu #10 (desno) u tvornici „KIO Keramika“, Orahovica.	84

Slika 5.4.	Pearsonov koeficijent korelacije izračunat između svakog procesnog signala i signala QC za preše #9 i #10 u tvornici „KIO Keramika“, Orahovica.	85
Slika 5.5.	Impaktogram za prešu #9 u tvornici „KIO Keramika“, Orahovica.....	88
Slika 5.6.	Impaktogram za prešu #10 u tvornici „KIO Keramika“, Orahovica.....	88
Slika 5.7.	Impaktogram za signale dvokanalne peći pri radu s pločicama iz preše broj 10 - prvih 18 smjena u 8 mjesecu 2009 godine: bijela polja su različiti kodni znakovi prema znaku QC signala, a plava i crvena za iste kodne znakove mjernih signala i signala QC. Crvena polja označavaju gotovo identične iznose teselacijskih entropija temperaturnih i QC signala	92
Slika 6.1.	Shema sveobuhvatne kontrole kvalitete u proizvodnom procesu. Mjerni signali kvalitete i izvršni/kontrolni signali procesa naznačeni su strelicama od/i prema pojedinim procesnim dijelovima.....	100
Slika 6.2.	Dijagrama toka kontrole signala kvalitete sa slike 6.1. Vremenske konstante τ_1, \dots, τ_{RM} određuju specifični procesni dijelovi.....	101
Slika 6.3.	Dvostupnjeviti postupak u sustavu kontrole kvalitete proizvoda	102
Slika 6.4.	Kontrolne točke u procesu proizvodnje prešanjem.....	103
Slika B.1.	Model procesa – blok shema realizacije proizvodnje	152
Slika B2.	Realizacija proizvodnje po sektorima u KIO Keramika d.o.o.	158
Slika B3.	Grafički prikaz aktivnosti pri realizaciji proizvodnje	160
Slika B4.	Kontrolne točke u procesu proizvodnje prešanjem.....	163
Slika C1.	Klaster analiza na razini cijele Organizacije bez proizvodnog sektora.....	170
Slika C2.	Klaster analiza na razini proizvodnog sektora	171
Slika D1.	Impaktogrami s preša 6, 8,5,10 i 9	175

Popis tablica

Tablica 2.1 Opis rangiranih izvjesnosti detekcije greške prema projektu, po FMEA.....	10
Tablica 2.2. Prikaz binarno kodiranog procesnog signala za četiri uzastopne promjene.....	17
Tablica 3.1. Primjeri pet jediničnih procesnih komponenti.....	54
Tablica 5.1. Abeceda i kodirane dinamičke promjene signala.....	68
Tablica 5.2. Informacijski sadržaj skokovno opisane Carnapove entropije	76
Tablica 5.3. Informacijski sadržaj znakova abecede nakon ekspanzije	78
Tablica 5.4. Uzdužni raspored temperaturnih senzora, temperatura, postavnih iznosa i izmjerenih temperatura za keramičke pločice SKY YEL dimenzija 250x200 mm; pripadne greške i stanje dojava; sve za kanal 1 dvokanalne peći Siti.....	89
Tablica 5.5 Dio podataka QC signala i signala s dvokanalne peći s preše sirovih pločica u razdoblju 8 i 9 mjeseca 2009 godine; svi signali dvokanalne peći s44-s51 su iz područja zone maksimalne temperature i dani su u stupnjevima celzusa; QA signala je dan u postotku škarta završne kontrole	91
Tablica 5.6. Izračuni entropija za signale s dvokanalne peći za šarže s preše broj 10 – posebno su u redu 15 i 16 označena podudaranja entropijskih vrijednosti QC i s50 signala.....	92
Tablica 6.1. Popis i opis signala kontrole kvalitete u pogonu proizvodnje keramike prešanje	104
Tablica C.1 Značajke kvantitativnih i kvalitativnih metoda.....	167
Tablica C.2. Srednjaci udaljenosti	172
Tablica D1. Entropije signala s44 do s51 na preši 9.....	177
Tablica D2 Entropije signala s44 do s51 na preši 10.....	178

Popis simbola

x_i	uzorak signala
N	broj odsječaka motrenja faznog prostora
L	J ednodimenzijski prostor mjerenja
N	broj mjerenja
d_i	područje zauzimanja i-tog uzorka mjernog signala
x_k	ukupno područje obuhvata svih mjernih uzoraka
Δ	jedinični skok pri delta modulaciji
$(L_1, L_2, L_3, \dots, L_k)$	skup mjernih podataka
$X = (X_1, X_2, X_3, X_4)$	mjerna četvorka uzoraka signala
T_i	jedna od šest stvarnih razlika svih četiriju uzoraka signala
QC	signal kontrole kvalitete
m	broj mjernih signala
$S, S_i, S'_{i,j}$	skup mjernih signala, mjerni signal, j-ti uzorak i-tog mjernog signala
E	skup svih mjernih događaja
L	duljina niza kodnih znakova
I_i^j	proširena teselacijska entropija kodnog znaka
I	matrica svih signalnih entropija
I_{QC}	ekspandirana teselacijska entropija signala kvalitete
γ	skladnost kodnih znakova procesnih signala i signala kvalitete po vrsti koda i iznosu ekspandirane entropije popločenja
$P(i)$	vjerojatnost pojave znaka i
$\Delta_{i,j}$	jedinična promjena između mjerenja i te mjerenja j
λ'	poredani podskup relevantnih mjernih događaja kontrole kvalitete
$Carn_{1D}$	Carnapova entropija 1-dimenzijskog prostora
θ	Prag neosjetljivosti na promjenu mjerne veličine
S	Slova abecede
Z	Šestorka sortiranih veličina
$AlphEn$	Abecedna entropija za bilo koja četiri uzastopna mjerna signala
B	Faktor poboljšanja kvalitete procesa
τ_s	Vremenska konstanta kontrole kvalitete

τ_p	Vremenska konstanta nadzora kontrole kvalitete
----------	--

1. UVOD – MOTIVACIJA I OKOLIŠ PROBLEMA

Proizvodna djelatnost je najvjerojatnije najstarija organizirana ljudska djelatnost. Razvija se od neolitika i često je jedina materijalna ostavština pojedinih kultura. Razvojem proizvodnje su se u tijeku industrijalizacije razdvajale na zasebne industrijske i obrtne grane: poput industrije metala i nemetala, proizvodnje i prerade hrane, rudarstvo, energetika i srodne grane u kojima prema organizaciji proizvodnje razlikujemo kontinuirane, polu obročne i obročne te komadnu proizvodnju.

Hrvatska industrija započela je svoj razvoj u XVIII stoljeću za Zrinskih i Frankopana no ubrzo je znatno nazadovala gušenjem Zrinsko-Frankopanske bune. Ponovni polet je hrvatska industrija započela u drugoj polovici XIX stoljeća.

Kako bi se današnja industrijska proizvodnja mogla „nositi“ sa zahtjevnom svjetskom konkurencijom na tom području potrebno je osigurati, pored gotovo idealnih sirovina, odgovarajuću energiju, ustrojiti visoko proizvodne robotizirane linije i uvesti moderne metode vođenja kvalitete proizvoda uz posebnu pozornost zaštiti okoliša.

Sve navedeno postavlja ekstremne zahtjeve na cjelovitost složenog i osjetljivog proizvodnog procesa osobito na školovanost i obrazovni profil radne snage. Bit sagledavanja svih vidova kvalitete i visoke produktivnosti pogona tada se sastoji od uspješnog savladavanja i ovladavanja svim informacijskim tokovima i vidovima proizvodnje, onima u tehnološkom procesu i onima kod ljudskih resursa s naglaskom na potpunom menadžmentu kvalitete (engl. TQM – Total Quality Management), procesu koji je u smislu norme rezultat dogovorene kvalitete s kupcem prenesen na proces, praćen u procesu i poboljšavan u tijeku proizvodnje u zatvorenoj petlji povratne veze. Bez takvog sustava proizvodnje modernoj industriji nema opstanka.

U navedenom ćemo radu istražiti problem škarta u proizvodnji keramičkih pločica, gdje dozvoljeni škart iznosi 6%. Kada škart prelazi 6% a često doseže i 9% poduzimaju se korektivne mjere s neizvjesnim ishodom. No prateći informacijske tokove u tako oblikovanom proizvodnom procesu pokušava se odrediti mjesta potencijalnog uzroka škarta s ciljem stavljanja pod nadzor škarta i ispod navedenih 6%. Daju se teorijski i praktički odgovori na navedene probleme, uz izdvajanje problema s radnom snagom, njezinom motivacijom i obrazovanjem. Navedena analiza odnosi se i na industrijsku proizvodnju u području materijalnih proizvoda što isključuje energetiku. Budući da je ovime u proizvodnom sustavu podsustav energetike izdvojen, u ovom se radu razmatra informacijski i materijalni podsustavi proizvodnje i cjelina njihova međudjelovanja u smislu ostvarenja zadataka TQM-a.

1.1. Informacijski podsustav proizvodnje i suvremena znanost

Newtonovska je fizika dominirala znanošću u periodu od kraja sedamnaestog do kraja devetnaestog stoljeća. To je razdoblje kada se gotovo bez ijednog suprotnog glasa smatralo da je stvarnost i svemir jedan nepogrešivi cjeloviti mehanizam kojem je cijela budućnost ovisila o cjelokupnoj prošlosti. Takva se slika svijeta pokusom ne može potpuno opravdati no niti potpuno odbaciti i spada u velikoj mjeri dodatku bilo kojeg pokusa kao nešto što je iznad svakog dokazivog pokusa [1]. Razlog takvog stanja jest nesavršenost našeg pokusnog postupka i opreme.

No, dvojica su fizičara, Boltzmann u Njemačkoj i Gibbs u Sjedinjenim Američkim Državama doprinijeli tome da se newtonovski svijet nepovratno srušio. Boltzmann i Gibbs su naime unijeli statistiku u fiziku i to na obuhvatniji način, tako da su statistički pristup opravdali ne samo za sustave velike složenosti već i za tako jednostavne slučajeve poput ponašanja jedne čestice u polju sile. Pretpostavka da se dva ili više sustava iste ukupne energije mogu zauvijek razlikovati bila je oborena. Statistika se kao znanost o razdiobama pri tome nije odnosila na razdiobu velikog broja čestica već više na način na koje se neki sustav može pokretati iz različitih stanja i pozicija.

Naravno da se neodređenost (nesigurnost) mjerenja već implicitno nalazila i u Newtonovu sustavu razmišljanja, no nitko se o tome nije izjašnjavao u osamnaestom stoljeću. Zasluga Gibbsa bila je ta što je ukazao na nepostojanje kauzalnosti odnosno na kontingentnost stvarnosti. Kasnija istraživanja, osobito filozofa, poput Wittgensteina 1913. godine, te matematičara Lebesguea i Borela dala su tom razmišljanju potpunu utemeljenost. Takva neodređenost bila je bliska već i razmišljanju sv. Augustina u obliku „negativnog zla“ koje nastaje zbog nepotpunosti za razliku od „pozitivnog zla“ manihejaca [2].

Novost koju je unio Gibbs u fiziku bila je razmatranje svijeta ne kao jednog svijeta već svijeta kao svih mogućih svjetova koji su mogući odgovor na ograničeni skup naših pitanja o našoj stvarnosti. Vjerojatni broj svjetova s povećanim brojem naših pitanja, prema osnovnoj Gibbsovoj teoriji, raste kako svemir stari. Mjeru tog povećanja Gibbs je nazivao entropijom koja je pokazivala značajnu težnju povećanju protokom vremena. U Gibbsovu načinu promatranja svijeta red je bio najmanje vjerojatno stanje, a kaos najvjerojatnije stanje svijeta. No pojedine izolirane cjeline takvog svijeta imale su po Gibbsovu mišljenju smjer razvoja suprotan općem kretanju i u njima su postojali, istina ograničeni i privremeni, uvjeti sklonosti rasta organizacije. U nekim takvim enklavama svijeta život je našao svoj dom. S tim ključnim mišljenjem stvorena je i znanost o vođenim sustavima – kibernetika [1].

Povijesno se kibernetika počela razvijati tek poslije Drugog svjetskog rata, iako su prethodnici vođenih sustava i automata poznati znanstvenici poput Fermata, Huygensa, Leibnitza i Maxwella. Pri samoj definiciji kibernetike Norbert Wiener je već 1950. godine zajedno svrstavao komunikaciju i vođenje (engl. communication and control). Razloge za to navodi Wiener kao: “komunikacija među ljudima uključuje moju poruku drugome i njegovu, meni nepoznatu poruku, natrag, odnosno kao i kada kontroliramo akciju druge osobe, komuniciramo mu poruku, koja iako je data u naredbodavnom obliku, upotrebljava tehniku kojom se izvodi nimalo različitom od poruke o nekoj činjenici” [1]. Nadalje, navodi Wiener, ako želim da moje vođenje bude učinkovito moram raspoznavati svaku poruku od svog sugovornika koja može naznačivati da je razumio nalog i da ga izvršava. Ovo se prema Wieneru odnosi

podjednako na komunikaciju među osobama, među automatima kao i na međusobnu komunikaciju osoba i automata.

Neovisno o Wienerovoj teoriji kibernetike razvijala se pod dalekim utjecajem Willarda Gibbsa i Boltzmannova statistička teorija komunikacije, podržavana radovima Nyquista, Fanoa, Hartleya, Shannona i mnogih drugih autora kojima je glavni razlog bio vrlo praktične prirode, uzrokovan neposrednim problemima s komunikacijom signala u ratnim uvjetima Drugog svjetskog rata, a to je bilo pitanje optimalnog ili bolje reći maksimalnog iskorištenja nekog komunikacijskog kanala u prisutnosti šuma. Šum je unosio statističku komponentu u prijenosu elektromagnetskog ili električnog signala i ometao svojom nepredvidivošću prijem vrlo malih signala na daljinu. Rješenja koja je nudila praksa bila su rad na kanalu s vrlo malim brzinama prijenosa signala, no takva rješenja zahtijevala su relativno duga vremena prijenosa poruke i, povezano s time, neučinkovitost „ratnog stroja“. Na ova pitanja djelomičan odgovor dao je Claude Shannon svojom teorijom informacije 1949. godine [2].

Poticana Wienerovim istraživanjima razvila se, neovisno o njegovoj gotovo humanističkoj sintezi rada ljudi i strojeva, von Bertalanffyjeva teorija sustava 1956. godine. Ludwig von Bertalanffy (1901-1972) bio je biolog i filozof koji se razvio pod utjecajem filozofa Rudolfa Carnapa i Gustava Fechnera. Njegova opća teorija sustava (OTS) je pokušaj uvođenja inačice dotada konvencionalnom modelu organizacije. OTS odredila je nove temelje i razvoj teorije sustava s primjenama na različita područja studija naglašavajući prevlast holizma nad redukcionizmom, organizma nad mehanizmom.

Von Bertalanffy je dao najveći doprinos teoriji sustava svojom teorijom otvorenih sustava. Teoretičari sustava smatrali su model zatvorenog sustava zasnovanog na klasičnoj fizici i na drugom zakonu termodinamike neodrživim. Bertalanffy je smatrao da je „konvencionalna formulacija fizike, u principu, neprimjenjiva na žive organizme koji su otvoreni sustavi u stacionarnom stanju. Možemo stoga opravdano sumnjati da su mnoge glavne značajke živih sustava, koje su paradoksalne u smislu zakona fizike, upravo posljedica te činjenice“ [3].

No pitanja na koja nije odgovarala fizika zatvorenih sustava nisu garantirala niti da će ih riješiti teorija otvorenih sustava. U modelu Bertalanffyja teoretičar definira opće principe otvorenih sustava i ograničenja konvencionalnih modela. On je razmatrao primjenu svoje teorije na biologiju, teoriju informacije i kibernetiku. Bertalanffy je zapazio i neriješene probleme koji uključuju trajna pitanja koje postavlja termodinamika i nezamjenjivo pitanje poopćenja zakona fizike posebno u teoriji informacije koja zahtijevaju daljnja istraživanja i imaju potencijal na primjenu u otvoreno sustavskom pristupu fizici. U sustavskom pristupu društvenim znanostima Bertalanffy je vjerovao da je OTS primjenjiva na sociologiju kao opći sustav povratne veze, informacije i komunikacije. Njegova kritika dotadašnje sociologije ukazivala je na njen redukcionistički duh. OTS podržava modernu težnju interdisciplinarnosti u znanosti, a posebno u sociologiji.

Stoga se proizvodna djelatnost u industriji kao tipičan otvoreni sustav s jakom interakcijom ljudi i strojeva podvrgava u teorijskom smislu općoj teoriji sustava, kibernetici, teoriji informacije i komunikacije te će se u tom smislu i razmatrati dalje u ovom radu.

Zbog pragmatičkih razloga ograničit ćemo se na tri radne hipoteze:

- a) Praćenjem parametara kvalitete u okviru preporuka proizvođača opreme moguće je pronaći smetnje kao utjecajne veličine na kvalitetu proizvoda
- b) Analizom kodnog obrasca utjecajnih veličina procesa pomoću ekspanirane 1D Carnapove entropije moguće je pravodobno otkriti mjesto nastanka poremećaja procesa proizvodnje
- c) Otklanjanjem otkrivenih poremećaja moguće je poboljšati ekonomičnost automatizirane proizvodnje u keramičkoj industriji.

U drugom poglavlju opisani su stoga procesni signali, dan je opis proizvodnih procesa i procesnih smetnji te se postavljaju pitanja o mogućnosti detekcije i otkrivanja greške. Analizira se utjecaj poznavanja dinamike procesa na detekciju i otkrivanje procesnih smetnji. Razlaže se

detekcija vremenskih serija praćenjem dinamike procesnih obrazaca te se vrši usporedba korištenja procesnih obrazaca uporabom Shannonove i Carnapove 1D neekspandirane i ekspandirane entropije.

Treće poglavlje sadrži prikaz važnosti informacije i informacijskih pravilnosti te njihovog adekvatnog matematičkog modeliranja. Dan je pregled različitih pristupa u izučavanju informacijske makro i mikro dinamike. Definira se pojam kvalitete i kontrole kvalitete u proizvodnim procesima te se detaljno opisuju neke od postojećih metoda za upravljanje kvalitetom poput Ishikawa dijagrama, metode kontrolnih karti, regresijske analize, Pareto dijagrama, dijagrama raspršenja, potpunog upravljanja kvalitetom i sličnih metoda. Definira se i klasificira jedinični proizvodni proces te se razmatraju mogućnosti za njegovo poboljšanje. Procesni tok definira se kao niz slijedno povezanih jediničnih procesa.

U četvrtom poglavlju dan je kritički osvrt na postojeće metode upravljanja kvalitetom te su istaknuti nedostaci postojećih metoda kod primjene u dinamičkoj okolini. Uvodi se pojam teleonomije (svrhovitog ponašanja sustava) u automatskim proizvodnim sustavima s primjerom temeljnih zahtjeva kvalitete prema normi ISO 13006. Razmatraju se nedostaci primjene Shannonove informacijske mjere u svrhu procjene teleonomije sustava te se postavljaju kriteriji koje bi informacijsko mjerenje za procjenu teleonomije u automatiziranim proizvodnim sustavima trebalo ispuniti.

Peto poglavlje sadrži prijedlog informacijske obrade i generiranje procesnih obrazaca temeljenim na modificiranom Carnapovom konceptu entropije. Predstavljena je metoda abecedne entropije kao proširenje originalne jednodimenzionalne Carnapove entropije uvođenjem matrice razlika uzastopnih diskretnih mjerenja. Predstavljene su osobine i dan je matematički aparat za izračun abecedne entropije za vremenski ograničeni procesni obrazac. Dan je izvod abecedne entropije kao proširene 1D Carnapove entropije s uzastopnim mjerenjima i međusobnim razlikama mjerenja. Prikazan je informacijski sadržaj binarno i terarno kodirane abecedne entropije. Predstavljen je postupak primjene entropije proširenog mjernog signala na kontrolu kvalitete obročnog industrijskog procesa. Predloženi postupak

sastoje se od pet uzastopnih i dobro definiranih koraka te je primjena postupka prikazana na primjerima određivanja potencijalnog mjesta kvara na proizvodnoj preši i dvokanalnoj peći u keramičkoj industriji.

U šestom poglavlju razmatra se odnos između informacijskog objekta i informacijskog modela te nemogućnost potpuno preciznog modeliranja promatranog objekta. Pored vjerodostojnog informacijskog modela potrebno je osigurati i primjereni sustav prikupljanja i obrade podataka, a sve u svrhu praćenja kvalitete proizvoda. Dan je prikaz tokova materijala i tokova kontrole kvalitete u konkretnom industrijskom pogonu te je istaknuta nužnost njihova poznavanja i poznavanja njihova međudjelovanja za kvalitetu konačnog proizvoda. Na primjeru slijednog industrijskog sustava dan je prijedlog modela upravljanja kvalitetom te je načinjena jednostavna financijska analiza opravdanosti sustava kontrole kvalitete na konkretnom primjeru.

Sedmo poglavlje donosi raspravu o potrebi uvođenja novih metoda za kontrolu kvalitete u visoko automatiziranim procesima. U tu svrhu koristili bi se procesni signali proizvodnje koji se odabiru prema vezi s kvalitetom konačnog proizvoda. Analizira se mogućnost i svrhovitost primjene novopredložene metode u visoko automatiziranom procesu. Analiziraju se prednosti i nedostaci novopredložene metode i ističe mogućnost primjene na kratkim slijednim podacima za koje nisu pogodne uobičajene metode. Razmatraju se prednosti i nedostaci automatskog određivanje entropije proširenog mjernog signala i automatske interpretacije impaktograma. Usprkos određenim ograničenjima predložene metode ističe se da je predloženi postupak primjenjiv na bilo koji industrijski proces u kojem se prikupljaju procesni podaci, a koji je poznat po povremenim greškama odnosno defektima u proizvodnji.

U osmom poglavlju dan je zaključak u kojem se obrazlaže ostvarivost radnih hipoteza doktorske disertacije, primjenjivost predložene metode i potrebi pravodobne detekcije mjesta nastanka smetnje, a sve u svrhu unapređenja sustava kontrole kvalitete i poboljšanja ekonomičnosti proizvodnje.

2. PROCESNI SIGNALI - OPIS PROIZVODNIH PROCESA I PROCESNIH SMETNJI

2.1. Poznavanje dinamike procesa detekcijom i otkrivanjem procesnih smetnji

Pri razmatranju izvora znanja Karl R. Popper vrši zamjenu pitanja: „Koji su najbolji izvori našeg znanja – najpouzdaniji, koji nas neće dovoditi u grešku i kojima se možemo obratiti, u trenutcima sumnje, kao najvišem sudu?“, kada navodi naoko potpuno drugačije pitanje „Postoji li način detekcije i otkrivanja greške?“ [4]. Dakle pitanje izvora znanja kao i ostala pitanja autoriteta jest pitanje izvora, izvornosti našeg znanja. Pitanje je možda podsvjesno motivirano pitanjem postojanja racionalnog „čistog znanja“, znanja koje posjeduje neki najviši autoritet. Modificirano pitanje o nadi u mogućnost otkrivanja greške proizlazi iz uvjerenja da takvi izvori ne postoje, pri čemu se to pitanje ne smije pobrkati s pitanjem valjanosti i pitanjem istine [4].

Općeniti odgovor na pitanje detekcije i otkrivanja greške svodi se primarno na kritiku postojeće teorije i njezinih zaključaka, izvoda, dakle spekulativnih pokušaja rješavanja problema putem postojeće teorije. Dakle, postavlja se osnovno spoznajno ili epistemološko pitanje: „Što je izvor nečijeg razmišljanja?“ Ovo intrigantno pitanje međutim nema puno sveze s istinom, jer ne razmatra se kako je netko nešto domislio već može li se time riješiti postavljeni problem. Dakle, ako postoji zanimanje za rješenje problema onda bi propitivanje o porijeklu nečije ideje rješenja bila očita stranputica. Bolji postupak jest objektivna i oštra kritika iznesene ideje. Ovdje Popper postavlja osam teza u svezi s izvorima znanja odnosno izvorima i detekciji greški[4]:

1. Ne postoji konačni izvor znanja, već je svaki izvor, svaka sugestija dobrodošla no mora se podvrgnuti kritici
2. Pravo pitanje spoznaje nije sam izvor znanja, mi se pitamo je li neka tvrdnja istinita, to jest slaže li se sa činjenicama, promatranjima.

3. Tradicija je osim urođenog znanja najbolji izvor znanja.
4. Činjenica da je većina našeg znanja sadržana u tradiciji ne znači da se moramo postaviti protiv nje, ili da je moramo podržavati, već da tražimo one male dijelove koji su izloživi kritičkom preispitivanju.
5. Znanje ne može započeti ni iz čega niti samo iz promatranja. Napredak znanja se sastoji u mijenjanju i prilagođavanju prethodnog znanja. Veći je napredak moguć samo mijenjanjem postojeće teorije.
6. Najvažnija funkcija promatranja i logičkog promišljanja jest da nam pomaže u propitivanju one smjele teorije koju trebamo, kada radimo s nepoznatim.
7. Naše se razmišljanje smije kretati u okvirima toga da se istodobno ne može biti precizan i istome dati potpuni opis – što je nešto preciznije to se više gubi na objašnjenju.
8. Svako rješenje neke situacije stvara novu neriješenu situaciju. Povećavanjem znanja samo povećavamo znanje o onom što još ne znamo.

Znanje i njegovo otkrivanje jest svakodnevica boljitka čovječanstva. Detekcija i otkrivanje greške je s druge strane po Edwardsu Demingu životno pitanje proizvodnih sustava, postrojenja, njihove konkurentnosti [5]. Tako ISO 22000 uvodi proaktivnu metodu za vrednovanje proizvodnih procesa sa stajališta analize učinaka i modova greški (FMEA-Failure Mode and Effect Analysis). FMEA identificira numerički ishod za „stanje greški“ u svakom koraku procesa tako da kvantificira: a) vjerojatnost pojave greške, b) vjerojatnost da greška neće biti detektirana i c) iznos štete koju ta greška može prouzročiti osoblju i opremi. Umnožak tih triju ocjena daje se kao rizični prioritetni broj ili RPN (engl. risk priority number) za promatrani mod greške. Zbroj RPN-ova za sve modove je obuhvatni RPN procesa. Kako organizacija radi na poboljšanju procesa, može se anticipirati i usporediti učinke predloženih promjena računajući hipotetski RPN za različite proizvodne scenarije. No ne smije se zaboraviti da je RPN usporedna mjera unutar nekog procesa, a ne i mjera rizika tvrtke izvan procesa ili u organizaciji iste [6].

Numerički se RPN kreće između 1 i 1000, gdje 1 označava praktički zanemariv rizik. Detekcija greške je pri tome jedini „čisto tehnički dio“, budući da ovisi, osim o detaljnom i specijalističkom znanju i o poznavanju tehnološkog procesa, te o senzori i informacijskoj obradi detektiranog podatka.

Raspodijeljeni proizvodni sustavi poput energetskog sustava posebno su osjetljivi na pravodobnu detekciju greške, ili kvara. Detekcija kvarova u ovakvim sustavima mora biti posebno organizirana kako bi se sve odvijalo asinkrono i nezavisno o samoj aplikaciji sustava. Ovakvi sustavi mogu posjedovati grozdove detektora za usmjeravanje detekcije kvarova [7]. Ovakvi sustavi moraju osiguravati toleranciju na kvarove mehanizmom orkestracije djelovanja kako bi se postigla tražena kvaliteta usluga [8].

Izvjernost detekcije greške međutim ne mora biti uvijek jednako pouzdana. Tako FMEA razlikuje deset kategorija pouzdanosti s obzirom na kontrolu projekta koje rangira prema tablici 2.1.

Tablica 2.1. Opis rangiranih izvjesnosti detekcije greške prema projektu, po FMEA

Detekcija greške	Kriterij: očekivanje detekcije primjenom nadzora	Rang detekcije
Potpuno neizvjesna	Primjenom nadzora neće se ili se ne može otkriti uzrok ili mehanizam greške ili tog nadzora nema	10
Daleko od moguće	Vrlo mala šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	9
Udaljena	Daleka šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	8
Vrlo niska	Vrlo mala šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	7
Niska	Mala šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	6

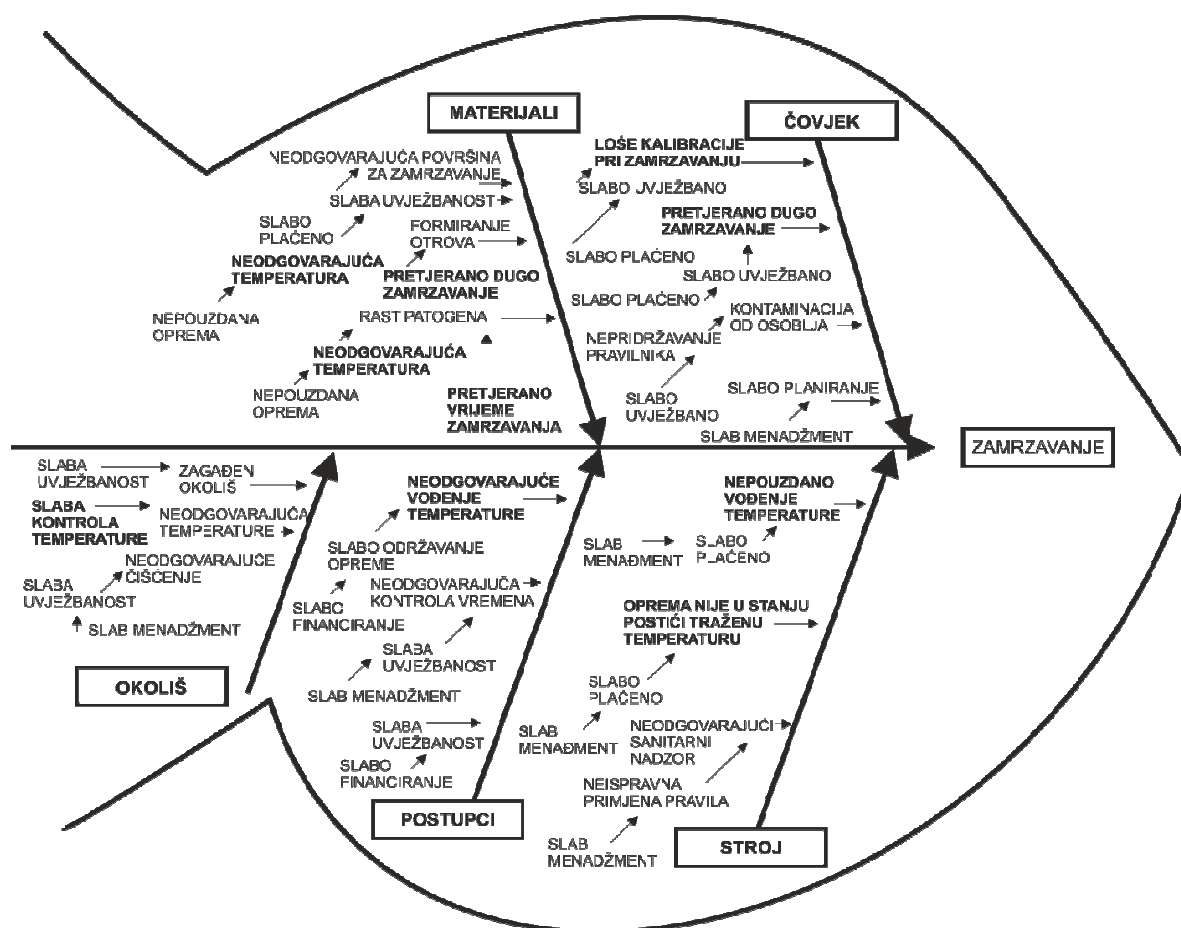
Umjerena	Umjerena šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	5
Umjereno velika	Umjerena velika šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	4
Velika	Velika šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	3
Vrlo velika	Vrlo velika šansa da će uprojektirani nadzor detektirati mogući mehanizam i pojavnost pogrešnog rada	2
Gotovo izvjesna	Uprojektirani nadzor će gotovo sigurno detektirati mogući mehanizam i pojavnost pogrešnog rada	1

Ovako prikazano vidljivo je da se ne očekuje da svi uprojektirani i izvedeni detektori imaju jednake šanse otkrivanja greške. Jednako tako prepoznate su uobičajene neispravnosti nazočne u navedenoj tehnici. To su:

1. Nedostatan motiv za poboljšanje projekta ili procesa zbog formalnog ili nedostatno motiviranog pristupa zadatku.
2. FMEA ne obuhvaća sve visoko rizične modove greške zbog poopćenosti ili prevelike detaljnosti pristupa. Ovo je osobito vezano na uvođenje nove tehnologije ili primjene postojeće tehnologije u novim aplikacijama.
3. Ne uzimanje u obzir sučelja i modova greški povezanih s integracijom sustava i podsustava, jer pogreške u sučeljima mogu izazvati pogreške u s njima povezanom sustavu.
4. Kašnjenje u uvođenju FMEA uzrokuje neučinkovitost proizvodnje, a neuključivanje u osnovni projekt postrojenja može rezultirati s lošim ishodom za vlasnika.

5. Nedostatak relevantnih osoba u ekipi poput projektanata, sistem-inženjera, osoba za testiranje, pouzdanost, održivost, proizvodnju, servis, kvalitetu i ostala područja važna za rad u smanjenom riziku. Sastanci ekipe moraju bit redovno posjećeni, jer već izostanak jednog člana ekipe može biti znak loše podrške rukovodstva postrojenja zadatku smanjenja rizika.

Pozicioniranje detektora potencijalne greške je primjer ekipnog rada. Pokažimo na primjeru sa Slike 2.1 takvu mogućnost na Ishikawa dijagramu pri proizvodnji zamrznute ribe na plovećim ribaricama [9], [10].



Slika 2.1. Uzročno posljedični ili Ishikawa dijagram na proces zamrzavanja ribe [9]. Posebno su u **boldanom** fontu naznačena mjesta mogućeg postavljanja detektora greške.

2.2. Opća teorija pojave smetnji za Poissonovu razdiobu pojava smetnji i proizvoljno kodiran procesni obrazac

Zamislamo proizvodni sustav s K detektora moguće procesne greške $d_i, i = 1, 2, \dots, K$, čije se dojave detekcije greške ravnaju po stacionarnoj Poissonovoj razdiobi. Neka su sve dojave jednako vjerojatne s učestalosti λ pa tako imamo linearni zakon o učestalosti λ_T dojava s brojem detektora K kao:

$$\lambda_T = K\lambda \quad (2.1).$$

Tako bi primjerice za deset detektora i $\lambda = 0,0001$ po detektoru taj iznos bio $\lambda_T = 0,001$.

Zamislamo također da se navedeni detektori ponašaju tako da proizvode analogne mjerne signale, dakle da se detekcija događaja odvija nakon izvlačenja informacijskog sadržaja iz signala u kontekstu procesnog trenutka. Dakle izuzimaju se oni signalizatori događaja uklopno-isklopnog tipa, jer su isti obuhvaćeni drugim procesnim mjerama koje se ne odnose se na rizične operacije s naslova kvalitete. U tom slučaju detektori generiraju kontinuirani mjerni signal koji se prikuplja u intervalima poput satnih, smjenskih ili dnevnih praćenja proizvodnje.

U svrhu dobivanja informacijskog sadržaja potrebno je izvršiti pretvorbu u kodni znak te primijeniti odgovarajuću entropijsku transformaciju [11].

Za kontinuirani mjerni signal $S_i \in R$ mogu se postaviti različite sheme kodiranja. U pravilu se sheme kodiranja mjernih procesnih signala temeljito razlikuju od kodnih shema komunikacijskih signala koje su isključivo binarne, zbog prirode ekonomičnosti prijenosa. Procesni signali mogu se podvrgnuti i ternarnoj kodnoj shemi. Kodiranje jako ovisi o primjeni tako da postoje posebni kodovi za GPS, akustičke, seizmičke, telegrafske, sigurnosne, transformacijske primjene poput kodiranja TV signala i tome slično.

Neka je sa stajališta detekcije greške mjerno zanimljiv samo dio L ukupnog mjernog signala L_{max} . Neka je trenutno izmjeren iznos x_i^t signala S_i unutar L . Budući da se iz tog mjerenja zbog logaritamskog zakona entropije ne može izračunati nikakav sadržaj informacije, potrebno je posegnuti za prethodnim vrijednostima istog signala, dakle za $x_i^{t-\delta}$, gdje je δ interval snimanja. Postupak se može formalno aproksimirati izrazom za mjerni opseg i -tog signala i rezoluciju mjerenja r_i nakon dva mjerenja kao broj kodnih znakova M tj. :

$$M = 1, 2, \dots, a_i^b = \frac{L}{r_i} \quad (2.2),$$

gdje je: a kodna osnova npr. $a = 2, 3, \dots$ za binarno, ternarno ... kodiranje a b je odgovarajući cjelobrojni eksponent. Tako za $r_i = 0,001$ i $L=80$ vrijedi:

$$M = \frac{80}{0,001} = 80000 \quad (2.3),$$

gdje je L mjerni opseg detekcije kvara signala S_i . Sljedeći korak, odnosno nakon tri mjerenja dao bi M^2 kodnih obrazaca, odnosno n -to mjerenja dalo bi W mjernih obrazaca kao:

$$W = M^{n-1} \quad (2.4).$$

Općenito bi za n snimanja sa K detektora i n mjerenja raspolagali sa W_K mjernih obrazaca

$$W_K = \sum_{j=1}^K M_j^{n-1} \quad (2.5).$$

2.3. Detekcija vremenskih serija praćenjem dinamike procesnih obrazaca

Postupci praćenja dinamike uporabom znakova – obrazaca se intenzivno koriste u razmatranju vremenskih serija u pojedinim područjima poput biomedicine [12], [13], [14], [15], [16], [17], posebno u kardiologiji [16], [17], u elektroencefalografiji [18], [19] te općenito u pripadnim analizama složenih vremenskih serija [20]. Većina autora koristi binarno kodiranje

obrazaca originalnih signala [12], [14], [17], iako se mogu primijeniti i ternarna kodiranja s prilagodljivim pragom odluke (engl. *threshold*) prilagodbe, osobito na procesnim signalima gdje je nedostatak promjene značajan za klasifikaciju znakova. Kodiranje s još bogatijim sadržajima znakova se ponekad istraživalo [21]. Obično se analizira nekoliko složenih svojstava tako kodiranih nizova znakova poput:

1. Entropija i informacijski zasnovane osobine izračunate iz svojstava razdiobe kratkih serija znakova [12], [15],[22].
2. Druge osobine dobivenih kompleksija poput Lempel-Ziv složenosti [18] te analiza fluktuacije s izbacivanjem trenda (engl. *detrended fluctuation analysis* DFA), [20].
3. Mjere sličnosti među kodiranim sljedovima znakova [14].

Uobičajeno korištene entropijske mjere su: Shannonova entropija [23], korelacijska entropija [24] te Rényiјеva entropija [25], [26]. Ove metode kvantificiraju informaciju kao topološku formaciju bez poziva na trajektoriju kretanja opažanog sustava u vremenu. Entropijski postupci koji razmatraju kretanje trajektorije sustava u vremenu zasnovane su na aproksimacijama Kolmogorovljeve entropije za mali broj mjerenja [27]. One uključuju: aproksimativnu entropiju [28], entropiju uzoraka [29], korigiranu uvjetnu Shannonovu entropiju [23] te noviju difuznu ili engleski fuzzy aproksimativnu entropiju [30]. Ove su se metode pokazale uspješne za analize vremenskih nizova u većini biomedicinskih vremenskih serija [18], [31], iako zahtijevaju teorijski promatrano analizu najmanje nekoliko stotina mjernih podataka [32].

Različit topološki pristup procesnim mjerenjima bio je predložen po Carnapu 1977. godine, prema podacima iz rada Pudmetzkog [33]. Ideja bijaše da se umjesto podjele d -dimenzijskog faznog prostora R^d u određeni broj ćelija s fiksnim volumenom v^d , fazni prostor podijeli na ćelije pridjeljive svakoj mjernoj točki. Podjela faznog prostora u takav okoliš naziva se Voronojevim popločenjem [34]. Entropijsku mjeru koju je Carnap definirao na Voronojevom dijagramu s proizvoljnom dimenzijom d poznata je kao Carnapova entropija.

Postupak s nekom od postojećih metoda simboličke dinamike uključivši i Carnapovu entropiju može se sažeti kao problem s:

1. Odvajanjem kvalitativnog postupka kodiranja od kvantitativnih metoda evaluacije kompleksije [12], [21], [14].
2. Nepostojanjem jamstva da će postupak evaluacije kompleksije dati različiti rezultat za dva skupa različitih sljedova, zbog različitih mogućnosti razlučivanja. Ovo ograničava preciznost tih metoda [17], [33].
3. Učinkovitim primjenom uobičajenih entropijskih metoda kada isto ovisi o velikom broju raspoloživih mjerenja procesnih signala [28],[32].

Metodologija koja se rabi zasnovana na abecednoj entropiji dobivena je iz Carnapove entropije i objašnjena u poglavlju 5. Ovo je nov i učinkovit postupak budući da rješava sva tri navedena problema pri učinkovitim i točnom kvantificiranju promjena na promatranoj kraćoj vremenskoj seriji procesnih podataka.

2.4. Usporedba korištenja procesnih obrazaca pri Shannonovoj i Carnapovoj 1D neekspandiranoj i ekspandiranoj entropiji

Izraz (2.5) odnosi se na obilje procesnih mjernih obrazaca pri konvencionalnom promatranju detekcije greške u procesu. Ovdje možemo međutim odmah uočiti razliku pri izračunu Shannonove entropije koja se za dobivanje distribucije koristi sumarnom mjerom promatranih obrazaca. Tako za binarni procesni obrazac znaka b s četiri uzastopne promjene, s tri koraka povećanja i jednim korakom smanjenja mjerenog signala, koje ga generiraju kao znak $++\pm I^M$, tablica 2.2, drugi redak, tek se ponavljanjem istog kroz još četiri mjerenja dobiva podatak upotrebljiv za Shannonov histogram vjerojatnosti pojave znaka b . Entropijski histogram znaka b dan je slikom 2.2. No zamijetimo da se i čistim generiranjem niza znakova b dobivaju dodatni znakovi iz tablice 2.2! Dakle neminovna je određena "razmazanost" znakova pri formiranju kratkih sjedova podobnih za izračunavanje pripadne Shannonove entropije.

Pogledajmo što bi značio niz promjena $\{+, +, +, -, +, +, +, -\}$ kao rezultat očitavanja devet uzoraka mjernog signala. Iz tablice 2.2 možemo razaznati da se radi o dekodiranom nizu znakova $\{b, c, d, g, b\}$. Iz ovog niza nismo u stanju izračunati pripadnu Shannonovu entropiju jer nemamo učestalosti znakova s dovoljno statističke uvjerljivosti. Tek pet i više puta produženom nizu istih znakova, dakle s najmanje 25 uzimanja uzoraka procesnog signala mogli bismo dobiti relativne frekvencije znakova s dovoljno statističke uvjerljivosti, te tako odrediti pripadnu entropiju. Naprotiv Carnapovu jednodimenzijsku entropiju mogli bismo izračunati već nakon pet uzoraka tj već nakon pojave prvog znaka s tablice 2.2. koristeći “zauzetost” prostora mjernog signala, slika 2.2 za znak ‘b’. Pripadni iznos entropije za znak ‘b’ bio bi:

$$C_{aren}(b) = \frac{L+\Delta/2}{L_{max}} \log A + 3 \frac{\Delta}{L_{max}} \log B + \frac{L_{max} - (L + \frac{5\Delta}{2})}{L_{max}} \log C \quad (2.7),$$

gdje su A , B i C kratice razlomaka ispred znaka logaritmiranja.


No zamijetimo odmah da bi Carnapova 1D entropija za znakove d i e , znakove j i k te znakove h i m s tablice 2.2. bila istog iznosa što nam ne bi dalo pravi opis pojave s pomoću Carnapove jednodimenzijske entropije!

Tablica 2.2. Prikaz binarno kodiranog procesnog signala za četiri uzastopne promjene, porast mjernog uzorka označava se sa + a pad sa -; četiri uzastopna znaka + su četiri porasta signala aproksimirana Δ -modulacijom


Slučaj	Signalni tijek	Znak	Kodna pozicija za izračun entropije									Jednakost entropija
			L-4Δ	L-3Δ	L-2Δ	L-Δ	L	L+Δ	L+2Δ	L+3Δ	L+4Δ	
1.	⁺⁺⁺⁺	a					x	x	x	x	x	
2.	⁺⁺⁺	b							x			
							x	x	x	x		
3.	⁺⁺⁺	c						x	x			
							x	x	x			
4.	⁺⁺	d					x	x				d=e
							x	x	x			
5.	⁺⁺	e					x	x				e=d
							x	x	x			
6.	⁺	f					x					
							x	x				
							x	x				
7.	⁺	g					x					

						x	x	x	x			
8.	l^{++-}	h					x					h=m
							x	x				
							x	x				
9.	l^{++-}	i					x					
						x	x					
						x	x					
10.	l^{++-}	j				x	x					j=k
					x	x	x					
11.	l^{++-}	k				x	x					k=j
					x	x	x					
12.	l^{++-}	N				x	x					
					x	x	x					
13.	l^{++-}	m					x					m=h
							x					
						x	x	x				
14.	l^{++-}	n					x					
					x	x	x	x				
15.	l^{++-}	o				x						
				x	x	x	x					
16.	l^{++-}	p	x	x	x	x	x					

Stoga je bilo nužno uvesti ekspanziju mjernog kodnog obrasca na način da su uzete u obzir i sve razlike koje se u svakom mjernom trenutku javljaju unutar svih mjerenja jednog znaka. Za znak 'b' i binarno kodiranje ovo bi značilo pretvorba mjernog niza {+++} s početnim mjerenjem L u ukupni niz sa svim razlikama između prvog i trećeg(+), drugog i četvrtog (+) i trećeg i petog uzorka mjerenja (0) te prvog i četvrtog (+) i drugog i petog (+) te konačno između prvog i petog uzorka mjerenja (+) tj. kao niz {+++; ++0; ++;+}. Pripadno prostiranje u 1-dimenzijском prostoru znaka 'b' dano je slikom 2.3. Vidimo da uvođenje ekspanzije koda navodi na postojanje i ternarnog elementa nepostojanja promjene tj. znaka „0“.




Slika 2. 2. Carnapova 1D entropija znaka 'b'; uočimo granice područja 'zauzimanja' označene sa $L + \Delta/2$, $L + 3\Delta/2$, $L + 5\Delta/2$ gdje je Δ korak delta modulacije pri aproksimaciji mjerenja, te udvostručenja zauzimanja na području $L + 2\Delta X$



Slika 2. 3. Ekspanzija pet mjernih uzoraka znaka 'b' {+, +, +, -} sa svim međumjerenjima na niz {+++; ++0; ++;+}.

Broj kodnih putova koji se ostvaruju za istovrsni ishod mjernog uzorka za ternarno kodiranje mjerne signalne promjene prikazana je slikom 2.4 za 1,2,3, 4 i 5 promjena pri uzorkovanju signala. Vidljivo je da je za veći broj mjerenja povećana vjerojatnost istog prostornog obrasca 1D Carnapove entropije, što je bilo ilustrirano i tablicom 2.2. Može se pokazati da se za četiri uzastopne promjene i ternarno kodiranje broj istih obrazaca penje za 49%.



Slika 2.4. Kumulacija obrazaca pri ternarnom kodiranju signala za 1,2,3,4, i 5 promjena signala

U svrhu određivanja poboljšanja kodnog obrasca uporabom ekspanzije odredimo prvo broj korištenih elemenata pri ekspanziji. Neka je n niz snimanih promjena ternarne aproksimacije. Broj elemenata matrice ekspanzije je n^2 , a broj dijagonalnih elemenata je n te je dužina ekspandiranog niza k jednaka broju elemenata matrice $n \times n$ umanjene za jednu polovicu elemenata ispod dijagonala ili

$$k = n^2 - \frac{n^2 - n}{2} = \frac{n^2 + n}{2} \quad (2.8)$$

Tako za $n=2$ imamo tri, za $n=3$ imamo šest, za $n=4$ imamo 10 elemenata k itd.

Kako za n koraka ternarne aproksimacije imamo n^3 znakova i $k^3 = \left(\frac{n^2+n}{2}\right)^3$ broja mogućih ekspandiranih znakova. Tako za $n=10$ imamo 3^{10} kodova i 3^{55} mogućih ekspanzija kodova. Za $n=3$ imamo 27 kodova te 729 ekspanzija. Dobitak ekspanzijom E na broju mogućih obrazaca iznosio bi za niz od n uzoraka na k ekspandiranih uzoraka kao

$$E = \left(\frac{n(n-1)}{2}\right)^3 \quad (2.9),$$

ili rasla bi sa šestom potencijom broja snimljenih procesnih uzoraka.

Više baze kodiranja na primjer četiri mogle bi se koristiti se pri kodiranju DNK obrazaca. Numeričko kodiranje DNK je moguće samo za neke fizikalne veličine poput loma svjetlosti. Napomenimo također da su binarna i simetrično kvartarno kodiranja, bez postojanja ništice, neizvedivi za ekspandiranje.

3. OPĆI UVJETI ODRŽAVANJA PROCESNE PROIZVODNJE

Istraživanje dinamike informacijskih obrazaca u proizvodnom procesu pretpostavlja definiranje sustava kao skupa međudjelovanja [35],[36]. Međudjelovanje bi predstavljalo svaku razmjenu zajedničkih supstancija poput energije, materije i informacije. Razmjena uključuje stvaranje, generiranje i prihvaćanje navedenih supstancija u svim svojim međudjelovanjima. Pojam skup bi se odnosio na sve elemente, entitete, koji međudjeluju u bilo kojoj supstanciji. Takva definicija skupa dana je u matematički strogom značenju a predstavljala bi konačan ili beskonačan zbir nedvosmislenih pobrojivih međudjelovanja elemenata, entiteta. Jedinstvenost međudjelovanja supstancija očituje se kroz pojam sustava ili podsustava, kao ciljnih, teleonomskih tvorevina [35], [36], [37], [38].

Ciljnost neke planirane akcije u proizvodnom sustavu ogleda se u više svojstava ponašanja takvog sustava:

- a) U određivanju konačnih svojstava proizvoda, njegovoj kvaliteti, kakva odgovara kupcu
- b) U određivanju objektivnih mjerila te kvalitete
- c) U određivanju kontrolnih mjerila, referentnih stanja u proizvodnom procesu u kojima se takvo buduće stanje može sagledati, bilo racionalnim razlozima poput gabaritnih svojstava proizvoda, bilo iskustvenim pokazateljima kojima se proizvodni postupci u svim svojim detaljima preslikavaju u zahtijevana svojstva proizvoda
- d) U određivanju proizvodnih pod ciljeva, dijelova proizvodnog procesa u kojima se može provoditi racionalna kontrola postignutih pod ciljeva proizvodnje.

Ciljnost je dakle zahtjev koji se mora moći i informacijski istražiti i dokumentirati [38],[39],[40]. Ciljnost je dio planiranja u sustavu menadžmenta svake tvrtke. Ona sadržava tehnološke, ljudske i ekspertne čimbenike i teško je odvojiva od konkretne poslovne situacije.

Stoga se odražavanje ciljnosti u svijesti radnika može mjeriti odnosom prema kupcu, dakle čimbeniku koji određuje temelje politike kvalitete neke tvrtke [41],[42].

Sustavno promatrano entiteti proizvodnje koji u svojem međudjelovanju čine sustav moraju se moći sagledati u svojim podsustavima ili njihovim dijelovima te u njihovom međusobnom skladu. Sklad u sustavu ostvaruje se prije svega informacijskom aktivnošću entiteta u kontekstu cjelovitog zadatka sustava. Stoga se sva pozornost istraživanja rada sustava posvećuje upravo istraživanju njegovog informacijskog vida postojanja, njegovog informacijskog podsustava [43].

3.1. Informacijski podsustav

Informacija je najopćenitija interaktivna supstancija. Informacija određuje sadržaj, smjer, karakter i smisao komunikacije različitih entiteta u proizvodnom sustavu. Njome se mjeri neodređenost pri prijemu informacije, a ona očituje svu raznolikost društvenih, prirodno-tehničkih i virtualno-modelskih međudjelovanja entiteta. Odatle se i sustav definira kao skup međudjelovanja entiteta s razmjenom informacije. Razmjena međudjelovanja informacije tvori nužne uvjete koje određuje vodstvo sustava, dočim se sposobnost kooperacije smatra dovoljnim uvjetom za funkciju i cjeloviti razvoj sustava [43], [44].

Sposobnost integracije sustava putem informacijskih entiteta može potaknuti zajednički cilj ili međusobna ovisnost, zajednički okoliš i tome slično. Ovo uključuje raznolike mehanizme kojima se tvori i u kojima se događa integracija, kooperacija i vezivanje poput sinergističkog djelovanja, koherencije različitih aktivnosti, sinkronizama i rezonancija različitih oblika, no nije isključena niti antagonistička komponenta među entitetima kao akterima i izvorima informacije [44],[45].

Takvo međudjelovanje je mnogostruko, stvaraju se neodređenosti u ponašanjima entiteta koje možemo opisivati slučajnim procesima [47],[48], [49]. Takvi slučajni procesi tvore skup slučajnih trajektorija koje predstavljaju stanja sustava. Informacijska znanost tada nastoji otkriti

opće pojavnosti i zakonitosti u danom sustavu putem praćenja skupova slučajnih trajektorija ponašanja sustava.

Zadatak danih matematičkih formalnosti teorije informacije jest da tvori matematičke modele i formalne jezike kojima se informacijske zakonitosti prevode u praktične postupke te alate kojima se svijet informacijske supstancije prevodi u računarske algoritme i programe za implementaciju u različitim materijalnim strukturama i humanim entitetima. Otkrivanje informacijskih pravilnosti, obrazaca, vodi na odgovarajuće kodove i sustavske modele kojima se zakonitosti ponašanja objekata odnosno entiteta mogu meritorno pratiti i kojima se može upravljati [50], [51].

Teorija informacijskog sustava je tada most i sredstvo između matematičkog formalizma i date informacijske tehnologije koja radi s informacijom kao nematerijalnom supstancijom, razvija sustavske modele, daje opis njenih izvora i tokova, njenih sustavskih mehanizama i rezultira na temelju dobivenih obrazaca u sustavskoj makrodinamici [39], [40].

3.2. Sustavski procesni obrasci i njihova dinamika

Informacijska makrodinamika razmatra informaciju kao proizvod svake i svih pojedinačnih međudjelovanja entiteta te studira informacijsku dinamiku rabeći makroskopski opis. Skupovi formalnih modela takvih višedimenzijских slučajnih procesa u vremenu i prostoru daju skupove slučajnih trajektorija sustavskih veličina koji se razvrstavaju prema vrstama u Gaussovske, Markovske, Wienerove, Poissonove procese, njihove podvrste te na druge vrste procesa [49]. Specifična analitička forma funkcija vjerojatnosti opisuje te vrste procesa.

Odgovarajuće mjere vjerojatnosti, koje smatramo modelskim mikroprocesima, sa skupovima mikrotrajektorija modeliraju rješenja višedimenzijских stohastičkih jednadžbi koje stvaraju slučajne mikroprocese [52]. Opće vrednovanje stohastičkih procesa na mikrorazini moguće je uporabom Kolmogorovljeve složenosti [53]. Markovljev model slučajnog procesa je uobičajen pristup u mnogim primjenama, kada se razmatra neki proces sam po sebi izdvojen iz okoliša [49], [54], [55]. Interaktivna stohastička kretanja omogućuju stvaranje modela nekih

regularnih dinamičkih procesa poput kristalizacije, termokonduktivnosti, termodifuzije, kemijskih reakcija, kinetike i hidrodinamike, konvektivnih procesa, te modela bioloških struktura kada nastaju procesi determinističkog kaosa iz nestabilnih dinamičkih procesa [51], [56], [57]. Regularnosti u promatranju makroprocesa doveli su do nekih poznatih zakona poput Ohmovog zakona, koji se odnosi na međudjelovanja u velikim skupovima slučajnih varijabli, ako sami potječu iz mikroprocesa.

I mikro i makroprocesi su općenito raspodijeljeni u prostoru i vremenu a njihov formalni model zahtijeva matematički formalizam za detektiranje pravilnosti u njihovoj pojavnosti slučajnosti. Tada se koristi informacijski oblik principa varijacije u obliku minimuma entropije promatranog sustava, točnije dobivanja maksimuma informacije iz minimuma raspoložive komunicirane informacije [2].

Makromodel se tada gradi u procesu izvlačenja regularne procesne mikrodinamike tako da se primljena informacija iznavljava u komunikacijskom procesu između makro i mikro dinamike. Važnu ulogu pri tome igraju referentne regulacijske veličine koje izvode povratnu vezu s makromodela na mjerni proces. To je slijedni postupak u kojem se model svaki puta iznavljava da bi anticipirao prijemnu informaciju [58].

Kontrolna komunikacija inicira kompenzaciju makromodela za neizvjesnost koju unosi proces svojim funkcioniranjem. Potrebna akcija u sustavu tada se koristi za izdvajanje informacije i uspješnu rekonstrukciju funkcioniranja i procesa i modela. Biološki sustavi posjeduju takvu akumulaciju životnosti zvane negentropija u obliku anticipacijskih akcija, a neživi proizvodni sustavi trebaju je generirati u sustavu vođenja i menadžmenta [51], [56],[57],[2].

Nepostojanje modela, kašnjenje izgradnje modela i nepostojanje negentropije u sustavu, sve to zasebno i uzajamno dovodi do neuspješnog i nekonkurentnog proizvodnog sustava [58],[59].

3.3. **Podsustav upravljanja kvalitetom**

U općenitom smislu, kvaliteta je svojstvo ili osobina koja označava određeni predmet ili pojavu, i razlikuje ih od ostalih predmeta ili pojava. Prema normi ISO 8402 kvaliteta je „ukupnost svojstava entiteta koja ga čine sposobnim da zadovolji izražene ili pretpostavljene uvjete“ po HR EN ISO 842, 1995. Iz ovih definicija slijedi da je kvaliteta radnja, proces, proizvod, organizacija, sustav, osoba ili neka od njihovih kombinacija.

Kvaliteta proizvoda se definira kao sposobnost za upotrebu proizvoda.

Općenito sustav organizacije za kvalitetu podrazumijeva sve planirane i sustavske akcije, neophodne da se garantira i osigura povjerenje kod kupaca da će konstrukcija, sustav ili komponenta zadovoljavajuće funkcionirati u eksploataciji – ovo znači da se zahtijeva određena strogost koja se provodi savjesno, provjerom izvršenja planiranih aktivnosti od strane ovlaštenih stručnjaka organiziranih u posebnoj organizacijskoj jedinici.

Dugi lanac poslovnog i proizvodnog procesa podsjeća da se greške mogu pojaviti bilo gdje i bilo kada. Greške mogu rezultirati u posljedice koje mogu ugroziti živote ljudi ili uzrokovati velike materijalne gubitke (atomske centrale, prijevoz, istraživanje svemira,...)

Kontrola kvalitete (KK), (engl. *Quality control*, ili QC), je proces kojim se revidira kvaliteta svih faktora uključenih u proizvodnju. Norma ISO 9000 / [60 ISO 9000:2015] definira kontrolu kvalitete kao "dio menadžmenta kvalitete u čijem žarištu interesa je ispunjavanje zahtjeva kvalitete".

Taj pristup stavlja naglasak na tri aspekta:

1. Elemente kao što su kontrole, upravljanje radovima, definiranim i dobro menadžiranim procesima, osobinama i kriterijima integriteta i utvrđivanja zapisa
2. Kompetencijama kao što su znanje, sposobnosti, iskustvo i kvalifikacije
3. Drugim elementima, kao osoblje, integritet, povjerenje, organizacijska kultura, motivacija, duh zajedništva i odnosi kvalitete.

Kontrole uključuju inspekciju proizvoda gdje se svaki proizvod kontrolira vizualno, često korištenjem mikroskopa za fine detalje prije nego se proizvod proda na otvorenom tržištu.

Kvaliteta izlaznog proizvoda je rizik ako je bilo koji od ova tri aspekta nedovoljan na bilo koji način.

Kontrola kvalitete naglašava testiranje proizvoda u svrhu otkrivanja grešaka i izvještavanje menadžmenta koji odlučuju o odobrenju ili odbijanju proizvoda, gdje osiguranje kvalitete pokušava usavršiti i stabilizirati proizvodnju i odgovarajuće procese kako bi se izbjegla, ili minimizirala djelovanja koja dovode do grešaka.

3.3.1. Metode upravljanja kvalitetom

Suvremene metode za upravljanje kvalitetom su nove strategije za smanjivanje troškova kvalitete, zaštitu okoliša, zdravlja i sigurnosti zaposlenika, odnosno podizanje opće razine kvalitete proizvoda kako bi se zadržali postojeći i pridobili novi korisnici [61]. Primjena metoda za upravljanje kvalitetom su alati za razvijanje funkcije kvalitete. Neke od često korištenih metoda opisane su u nastavku.


Ishikawa dijagram

Ishikawa dijagram (dijagram uzroka i posljedica, C&E dijagram, "riblja kost" [62] počeo je razvijati prof. Kaoru Ishikawa na Sveučilištu u Tokiju 1943. godine. Ishikawa dijagram predstavlja jednostavnu i vrlo korisnu metodu za sagledavanje što više mogućih uzroka koji dovode do posljedice/problema koji se analizira, sve u cilju poboljšanja i unapređenja poslovnih procesa u organizaciji. Vizualni prikaz uzroka koji ova metoda pruža olakšava analizu njihovog međusobnog odnosa i značaja. On grafički ilustrira odnos između prikazanog izlaza i svih faktora koji utječu na izlaz.

Ishikawa dijagram, u pravilu, izrađuje grupa stručnjaka koji imaju znanja o razmatranom problemu, a poželjno je da su u grupi pojedinci različitih kvalifikacija i raznih stručnih područja. Prema iskustvu Ishikawe, najefikasniji učinci postižu se radom u grupi od 4 do 8 ljudi pri čemu

rad grupe (izradu dijagrama) koordinira voditelj grupe. Tijekom izrade dijagrama rasprave trebaju biti svedene na minimum, a čime također upravlja voditelj grupe. Rasprava služi, u pravilu, samo za poticanje “oluje mozgova” (engl. *brainstorming*), a rezultat “oluje mozgova” pretače se u dijagram. Ishikawa dijagramom se stvara brza slika o problemu koji se rješava, te se vrlo efikasno dobiva odraz kolektivnog znanja.

Prilikom primjene Dijagrama uzrok-posljedica učesnici konstruiraju grafički prikaz uzroka organiziranih tako da pokažu njihov odnos sa specifičnom posljedicom.



Slika 3.1. Ishikawa dijagram – idejna zamisao

Konstrukcija dijagrama se sastoji od slijedećih koraka:

1. Identificiranje posljedice (problema) – na primjer velika potrošnja goriva
2. Identificiranje uzroka – na primjer greške osoblja, neispravni materijali ili metode vožnje
3. Identifikacija drugih faktora koji utječu na pojavu uzroka – na primjer kako do pojave uzroka korištenje neodgovarajućih metoda vožnje može dovesti prebrza vožnja, vožnja u pogrešnoj brzini itd.

Analiza dijagrama pomaže da se identificiraju uzroci koji opravdavaju daljnje istraživanje. Kako dijagram identificira samo moguće uzroke, tim u daljem radu može odrediti uzroke na koje će se prvo fokusirati. Prilikom analize, najvažnije je identificirati uzroke na kojima se mogu poduzeti odgovarajuće aktivnosti kako bi se postojeći utjecaji uklonili ili barem minimizirali. Dijagram rezultira s aktivnim traženjem uzroka problema. Na osnovi dijagrama mogu se ispitati, potvrditi ili odbaciti različiti mogući uzroci, sa svrhom koncentriranja na težinu određenih uzroka. Primjena dijagrama je široka, tj. on služi za poboljšanje procesa sa svrhom optimiranja, povećanja produktivnosti, smanjenja troškova itd., te za analizu grešaka, reklamacija i slično.

Kontrolne karte

Kontrolne karte su pogodne za ocjenjivanje stabilnosti procesa [63]. Služe za proučavanje variranja prosjeka, raspona i standardne devijacije za neki kontrolirani uzorak. Svaka kontrolna karta se grafički predstavlja kao dijagram. Na jednostavan način se vidi kada su potrebne korektivne mjere i da li je u određenom, promatranom vremenskom intervalu, došlo do poboljšanja. Upotreba kontrolnih karata u praćenju i mjerenju nekog procesa naziva se statistička kontrola procesa (engl. *SPC - Statistical Process Control*). Izrada kontrolnih karata se osniva na statistici i koristi se radi dijagnoze stabilnosti procesa, ili radi kontrole procesa ili radi potvrde da se proces odvija u zahtijevanim uvjetima. Kontrolne karte su dobre radi ranog otkrivanja pojave grešaka.

Kontrolna karta je „slika“ procesa. Kontrolna karta pokazuje kako se mjerni podaci (značajke procesa, proizvoda i slično) kreću u vremenu i što treba poduzimati u cilju poboljšavanja kvalitete. Osnovni su instrument pomoću kojega se provodi statistička kontrola proizvoda ili proizvodnoga procesa. Uloga kontrolnih karata je u otkrivanju i vizualizaciji poremećaja kvalitete proizvoda. Kontrolna karta predstavlja efikasan alat za reguliranje i upravljanje kvalitetom proizvoda i procesa rada. Koristi se kako u proizvodnim, tako i u uslužnim djelatnostima. Neke mogućnosti ovog alata su sljedeće:

- upravljanje kvalitetom procesa rada na bazi prostorne i vremenske slike stanja procesa, a u cilju sprečavanja proizvodnje nesukladnih proizvoda,
- kontrola kvalitete proizvoda u pojedinim fazama proizvodnje, fazi pripreme i fazi završetka, - stabilizacija procesa na osnovu otkrivanja nedopuštenih faktora i njihovog isključenja iz toka procesa,
- analiza točnosti i stabilnosti procesa rada,
- usavršavanje tehnoloških procesa rada s gledišta kvalitete,
- analiza grešaka obrade u toku odvijanja tehnoloških procesa,
- primjena u svim fazama nekog procesa (ulazna, procesna, izlazna kontrola i kontrola u eksploataciji) i svim tipovima proizvodnje (maloserijskoj, srednje serijskoj i masovnoj proizvodnji).

Zadatak primjene kontrolnih karti je:

- a) dovođenje procesa proizvodnje u stanje pod kontrolom,
- b) održavanje procesa proizvodnje u stanju kontrole (preventivna uloga)
- c) pokazati postignuto stanje kontrole.

Kontrolne karte temeljene na teoriji koju je razvio dr. Walter A. Shewart poznate su i kao Shewart-ove kontrolne karte [64], [65]. Tehnika se sastoji se od uzimanja većeg broja malih uzoraka iz procesa. Uzima se veći broj uzoraka kako bi povezanost između osnovnog skupa i uzoraka bila posve određena. Uzorci se, ako je to primjenljivo, uzimaju u slučajnim obilascima. Kontrolnom kartom se prate varijacije procesa u vremenu. To znači da uzorci uvijek moraju biti zadnje proizvedene jedinice. Varijacije unutar procesa mogu nastati kao posljedica dvije vrste uzroka:

1. opći ili sustavni (common causes), koji su svojstveni procesu (npr. genotipske varijacije),
2. specifični ili posebni (special causes), koji uzrokuju pretjeranu varijaciju.

Kontrolne se karte koriste za razlikovanje tih dviju vrsta varijacija u procesu, na osnovu analize podataka iz prošlosti i budućnosti (procjena). Uklanjanjem posebnih uzroka, proces se

dovodi u stanje statističke kontrole. Poboljšanje procesa zahtjeva identificiranje, prepoznavanje i uklanjanje općih ili sustavnih uzroka varijacija. Optimalnom primjenom kontrolnih karata osigurava se konstantno praćenje procesa, usmjeravanje ka željenom toku i poduzimanje eventualnih korektivnih mjera. Njihovom primjenom osigurava se ispunjenje projektiranih ili zahtijevanih karakteristika kvalitete, odnosno ispunjenje zahtjeva određenog standarda.

Konstrukcija kontrolne karte se sastoji od tri linije ucrtane u kontrolnoj karti, to su:

- Gornja kontrolna granica (engl. *Upper Control Limit-UCL*)
- Središnja crta (engl. *Central Line-CL*)
- Donja kontrolna granica (engl. *Lower Control Limit-LCL*)

Kontrolne granice izračunavaju se na tri načina:

- na temelju snimljenih podataka tehnološkog procesa (nepoznat proces – najčešći slučaj);
- na temelju zadane tolerancije karakteristike kvalitete koja se prati;
- na temelju poznavanja sposobnosti tehnološkog procesa (6σ).

Način konstrukcije kontrolnih karata i izračunavanja pripadajućih kontrolnih granica je prethodno nepoznat proces. Proces treba dakle najprije snimiti te na temelju prikupljenih podataka izračunati pripadajuće kontrolne granice. Nakon izračuna moguće je ocjenjivati stabilnost procesa temeljem prikupljenih podataka i njihovom „izgledu“ u vremenu. Kontrolne granice su statističke granice i nisu povezane s granicama zahtjeva definiranih od strane kupaca. Statistički značajna varijacija procesa uvijek je uočljiva, te iziskuje brzu akciju u otkrivanju uzroka varijacije. Središnja linija procesa predstavlja liniju aritmetičke sredine statističkog parametra koji se prati kontrolnom kartom. Ona predstavlja prosječnu vrijednost parametra karakteristike kvalitete koja odgovara stanju "pod kontrolom" kada su prisutni samo slučajni izvori varijabilnosti u procesu. Kontrolne se granice (donja i gornja) postavljaju, odnosno računaju na granice rasipanja ($\pm 3\sigma$) statističkog parametra (\bar{X} , R, s i druge statističke mjere) koji se prati kontrolnom kartom tj. računa iz uzorka. Mogu se koristiti i tzv. granice upozorenja koje se postavljaju na $\pm 2\sigma$ ili $\pm 1\sigma$. Nakon što kontrolna karta završena, sa ucrtanim kontrolnim

granicama, središnjom linijom, te podacima dobivenim iz uzoraka, može se prijeći na analizu stabilnosti procesa. Može se pojaviti jedan od slučajeva:

- Sve točke su unutar kontrolnih granica, simetrično izmjenično raspoređene oko centralne linije (CL). Proces je stabilan (pod kontrolom).
- Sve točke su unutar kontrolnih granica, ali su točke raspoređene većinom u nizu iznad ili ispod CL. Proces je stabilan, ali treba vidjeti zašto je nastao ovaj pomak.
- Jedna (ili dvije) točke nalaze se izvan kontrolnih granica. Pojedinačna točka (podatak) se izbacuje, a proračun CL i KG se vrši ponovo, bez nje. Ako se tada nijedna točka ne nalazi izvan KG, proces je pod kontrolom. Ako neke točke izlaze izvan novih KG, proces nije pod kontrolom.
- Više točaka je izvan KG. Proces je nestabilan.

Podatak izvan kontrolne granice (iznad UCL ili ispod LCL) pokazuje da se u procesu, statistički promatrano, dogodio značajan uzrok varijacije (odstupanja). U slučaju podataka izvan kontrolnih granica, ne znači da proces daje nesukladne jedinice (proizvode), upravo iz razloga što kontrolne granice nemaju veze sa granicama specifikacije, nego su to statističke granice. Kad varijacija prelazi statističke kontrolne granice, to je znak da su posebni uzroci ušli u proces i da proces treba ispitati, kako bi se oni utvrdili. Takav proces je „izvan kontrole“. Najefikasniji postupak poboljšavanja kvalitete praćenog procesa je žurno otkrivanje uzroka značajnih varijacija i provođenje popravni radnji. Poboljšavanja se sastoje od „sitnih koraka“ u dužem vremenskom razdoblju, te je važno znati kojim redom valja izvršavati korektivne mjere (izbor prioriteta). U slučaju kad nema podataka izvan kontrolnih granica onda se koristi termin „pod kontrolom“. To je statistički termin kojim se pokazuje da proces varira isključivo pod utjecajem slučajnih, procesu svojstvenih uzroka. Za pravilnu konstrukciju i primjenu kontrolnih karti, potrebno je na temelju mjerenja posljednje proizvedenih jedinica izračunati kontrolne granice i ocijeniti stabilnost procesa, te kartu s takvim kontrolnim granicama koristiti kao preventivni alat za buduće odvijanje procesa. Dinamiku korištenja kontrolnih karata treba prilagoditi učincima, mogućnostima poboljšavanja, preventivi i sl. Glavni ciljevi primjene kontrolnih karata su:

- dovođenje procesa u stanje statističke kontrole,
- utvrđivanje trendova i pomaka procesa u cilju zaštite od neželjenih rezultata (pojave dijelova lošije kvalitete, nesukladnih dijelova itd.),
- utvrđivanje potreba za remontom ili nabavom nove opreme, elemenata procesa i sl.,
- dobivanje svih saznanja o mogućnostima poboljšavanja procesa i mogućnostima postizanja zahtijevane kvalitete proizvoda (procjenjivanje sposobnosti procesa).

Razlikuju se dva tipa kontrolnih karata:

1. Kontrolne karte za mjerljive (numeričke) karakteristike,
2. Kontrolne karte za atributivne karakteristike.

Kontrolne karte za mjerljive (numeričke) karakteristike

Numeričke karakteristike kvalitete su svojstva koja se ocjenjuju brojnim vrijednostima kao npr.: temperatura, tlak, dužina, gustoća, snaga itd. Pri tome se koristi odgovarajuća mjerno-kontrolna i ispitna oprema. U ovu grupu kontrolnih karti pripadaju:

- \bar{X} – R kontrolna karta
- \bar{X} – s kontrolna karta
- \bar{X} – MR kontrolna karta za individualno praćenje kvaliteta (kontrolna karta sa pomičnim rasponom)

Matematička podloga ovih karata je normalna raspodjela.

\bar{X} – R kontrolna karta – ovom kartom se registriraju dva važna pokazatelja procesa a to su kretanje aritmetičkih sredina uzoraka, te kretanje raspona uzoraka Ri . Prvi podatak daje uvid u centriranost procesa, dok drugi Ri govori o njegovom rasipanju. Primjena ove karte dolazi do izražaja kod serijske i velikoserijske komadne proizvodnje, gdje se kontrola svodi na mjerenje malih uzoraka (u literaturi je navedeno $n=2$ do 10 komada[66],[65]).

\bar{X} –s kontrolna karta – karta prati dvije karakteristike procesa. Njegovu centriranost preko kretanja aritmetičkih sredina uzoraka, te njegovo rasipanje preko kretanja standardnih odstupanja. Budući da se računaju standardna odstupanja uzoraka preporučuje se da veličina uzorka bude veća od 25. Ove karte se primjenjuju u procesima koji su zaokruženog tipa i odvijaju se u zatvorenim ciklusima određene dužine trajanja kada se proces ne može pratiti dok je ciklus u toku.

\bar{X} –MR kontrolna kontrolna karta – karta se upotrebljava u situacijama kada se ne može omogućiti statistički uzorak, odnosno kada je veličina uzorka jednaka jedinici ($n=1$). Kod provođenja kontrole kvalitete svih sastavnica i podsustava tj. kod 100% kontrole kvaliteta, npr. kod složenih proizvoda, skupih agregata (turbine, generatori, pumpe) koje se rade u malim količinama, registriraju se parametri kvalitete i prate uz pomoć ove kontrolne karte.

Kontrolne karte za atributivne karakteristike

Atributivne karakteristike kvalitete su svojstva koja se ocjenjuju opisno pa se kaže da je nešto dobro ili loše, da odgovara ili ne, da ide ili ne ide, itd. Vizualna kontrola kvalitete je tipično atributivno ocjenjivanje. I kod atributivnih svojstava kvalitete, postoje mogućnosti ocjenjivanja putem odgovarajuće mjerno-kontrolne i ispitne opreme. U ovu grupu kontrolnih karti pripadaju:

- **np** kontrolna karta - neposredno prikazuje broj pronađenih škart jedinica u uzorku. Ova je karta primjenjiva kada je veličina uzorka konstantna.
- **p** kontrolna karta - prikazuje grafičko kretanje proporcije loših komada u uzorcima. Veličine uzoraka pri tome mogu biti različite. Matematička osnova je binomna raspodjela.
- **c** kontrolna karta - prati broj grešaka na jednom proizvodu ili uzorku. Uzorci moraju biti iste veličine.
- **u** kontrolna karta - prikazuje prosječan broj grešaka iskazan na jedinici proizvoda pronađenih u isporuci (uzorku). Veličine uzoraka pri tome mogu biti različite.

Analiza i tumačenje kontrolnih karata

Kod upotrebe kontrolnih karti koristi se standardna devijacija kao mjera rasipanja procesa. Gornja kontrolna granica se nalazi na udaljenosti od $+3\sigma$, a donja na udaljenosti od -3σ od središnje linije. Prostor između kontrolnih granica se dalje može podijeliti u tri zone. Zone su A, B i C polaze od središnje linije i koriste se u analizi i tumačenju kontrolnih karti.

Stabilnim procesom smatra se proces koji proizvodi rezultate procesa od kojih su svi, ili zadovoljavajući broj, unutar kontrolnih granica. Potpuno idealan proces ne postoji, ali treba težiti ka njemu. Pravila prema kojima se određuje stabilnost procesa su objavljena u dokumentima: [67],[68], [69], mogu se izdvojiti slijedeće stavke

- od posljednjih 25 točaka svaka se mora nalaziti unutar kontrolnih granica.
- među posljednjih 35 točaka jedna smije izaći izvan kontrolnih granica.
- od posljednjih 100 točaka najviše dvije točke smiju izaći izvan kontrolnih granica.

Može se dogoditi da su navedena pravila zadovoljena ali da proces i dalje nije stabilan. Situacije u kojima, pored navedenih, proces nije stabilan su sljedeće:

- Uzastopni porast ili pad srednjih vrijednosti uzoraka. Ako 7 točaka uzastopno raste ili opada proces nije u stabilnom stanju. Ako se dogodi da 5 uzoraka uzastopno raste ili opada tada je proces u kritičnom stanju. Proces je i dalje stabilan, ali to je znak da se može pojaviti nestabilno stanje. Ovakva situacija obično izaziva pomicanje centralne linije, što uzrokuje njezino odstupanje od osnovne mjere koja je zadana projektom.
- Zadržavanje srednjih vrijednosti uzoraka ispod ili iznad centralne linije. Ako se 7 uzastopnih točaka nalazi ispod ili iznad centralne linije, proces nije stabilan. Ovo stanje znači da je proces pomjeren, jer točke ne variraju oko željene centralne linije. Također vrijedi i pravilo da ako se dogodi da je 5 uzastopnih uzoraka ispod ili iznad centralne linije tada je proces u kritičnom stanju. Proces je i dalje stabilan, ali je to znak da se može pojaviti nestabilno stanje.

- Dvije od tri točke izvan područja 2σ upozorenja, ali ipak unutar kontrolnih granica. Ovo stanje se javlja u slučaju promjene procesa, opreme, metoda, materijala, izvršitelja posla ili promjene mjernog sustava.
- Četiri od pet točaka izvan 1σ kontrolnih granica. Često se javljaju veća odstupanja što bi proces moglo dovesti do nestabilnog stanja.

Procesi s trendom podataka

Sve je više poslovnih situacija u poduzećima u kojima menadžeri žele kontrolirati određenu varijablu, odnosno poslovni proces koji očekivano ima rastući ili padajući trend u vremenu. Kao npr. stanje zaliha, prinos proizvoda, stupanj produktivnosti, podaci o prodaji, trošenje alata itd. Sve je više situacija u proizvodnji i uslužnim djelatnostima gdje menadžeri ne žele koristiti statističke kontrolne karte kojima će pratiti samo jednu varijablu u vremenu. Želi se pronaći povezanost između dvije ključne varijable nekog procesa, te pratiti promjene u njihovoj povezanosti s vremenom. Tradicionalne Shewartove kontrolne karte, pokazale su se kao nepouzdanе za primjenu u takvim procesima. Zato je razvijena kontrolna karta koja omogućuje efikasno praćenje i ocjenjivanje takvih procesa, te se naziva regresijska kontrolna karta. Ova kontrolna karta je nastala kombinacijom konvencionalne kontrolne karte i regresijske analize.

Regresijska analiza

Regresijska analiza je statistički postupak za procjenu odnosa među varijablama [70],[71],[72],[73]. Cilj istraživanja odnosa među varijablama je utvrditi statističku ovisnost i pokazatelje jakosti takve ovisnosti. Regresijska analiza je matematički postupak za pronalaženje krivulje koja prolazi kroz zadani skup točaka uz minimiziranje sume kvadrata odstupanja zadanih točaka od te krivulje. Odnosi među pojavama (varijablama) mogu biti funkcionalni (deterministički) i statistički (stohastički) [74],[75]:

- Funkcionalni ili deterministički odnosi su postojani, izražavaju zakonitosti koje se iskazuju analitički (formulom, jednačbom). Svakoј vrijednosti јedne pojave odgovara točno određena vrijednost druge pojave.
- $y = f(x)$
- Statistički ili stohastički odnosi su deterministički slabiji od funkcionalnih. Jednoj vrijednosti јedne pojave odgovara više različitih vrijednosti druge pojave. Takva odstupanja su u praksi češća.

$$y = f(x) + e$$

gdje je: $f(x)$ - funkcionalna (deterministička) komponenta e - stohastička varijabla koja predоčuje nesistematske utjecaje na zavisnu varijablu.

Regresijska analiza uključuje tehnike za modeliranje i analizu varijabli, gdje se fokus stavlja na odnos između zavisne varijable i јedne ili više nezavisnih varijabli. Najčešće, regresijska analiza procjenjuje uvjetno оčekivanje zavisne varijable s obzirom na nezavisnu varijablu. prosječnu vrijednost zavisne varijable kada su nezavisne varijable fiksne. Ciljana procjena je funkcija nezavisnih varijabli odnosno regresijska funkcija. U regresijskoј analizi važno je karakterizirati varijacije zavisne varijable oko regresijske funkcije, a to se može opisati pomoću distribucije vjerojatnosti. Regresijska analiza se koristi za predviđanje i prognoziranje te za razumijevanje odnosa nezavisnih o zavisnim varijablama i istraživanje oblika tih odnosa. U slučaju regresijske analize zna se što je uzrok, a što posljedica nekog procesa (zavisna, nezavisna varijabla), a osnovni problem ove metode je одrediti koeficijente regresije. Razvijene su mnoge tehnike regresijske analize kao što su јednostavna, višestruka, linearna i nelinearna. Poznatije metode su linearna regresija i metoda najmanjih kvadrata gdje se regresijska funkcija definira preko konačnog broja nepoznatih parametara koji se procjenjuju na temelju podataka.

Jednostavna linearna regresija

Modelom jednostavne linearne regresije izražena je stohastička linearna veza između zavisne varijable y i nezavisne varijable x [76],[77]. Veza se može formalno opisati izrazom:

$$y = f(x) + \varepsilon \quad (3.1)$$

gdje je: $f(x)$ linearna funkcija varijable y , tj.

$$f(x) = \beta_0 + \beta_1 x \quad (3.2)$$

pri čemu su β_0 i β_1 nepoznati parametri pretpostavljene veze koju treba procijeniti, a ε je slučajna varijabla koja modelu daje stohastički karakter.

Pretpostavi li se da se linearna regresijska veza između varijable y i regresorske varijable x želi utvrditi na osnovi n opažanja (mjerjenja), tada se vektorska jednadžba može napisati u vidu sustava od n jednadžbi:

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i \quad i = 1, 2, \dots, n. \quad (3.3)$$

Jednadžba (3.3) se naziva i statistički model jednostavne linearne regresije. Polazne pretpostavke u analizi modela jednostavne linearne regresije su:

- a) Veza između zavisne varijable y i nezavisne varijable x je linearna.
- b) Varijabla y je deterministička varijabla ili se alternativno pretpostavlja da su njene vrijednosti fiksne u ponovljenim mjerenjima (uzorcima).
- c) Greške relacije u prosjeku ne utječu na zavisnu varijablu,
- d) Zbog jednostavnosti se pretpostavlja da je analizirani uzorak izabran na slučajan način, te da su stoga bilo koje dvije slučajne varijable ε_i međusobno nezavisne, a time su i nekorelirane.
- a) Također se polazi od pretpostavke da su ε_i normalno distribuirane slučajne varijable s jednakom varijancom.

Zadatak regresijske analize je da se pronađu procjene nepoznatih parametara (procjena vektora β_0, β_1) i procjena nepoznate varijance σ^2 slučajnih varijabli ε_i , i to tako da procijenjeni model bude "blizu" prave regresije. U ovom koraku pretpostavka o normalnosti distribucije slučajnog vektora nije bitna. Ta je pretpostavka važna u kasnijim koracima analize kako bi se mogli provesti postupci testiranja hipoteza o modelu.

Procjenjivanje sposobnosti procesa

Koncept statističke kontrole procesa temelji se na uspoređivanju podataka dobivenih iz procesa s izračunatim kontrolnim granicama te na osnovi toga donošenje zaključaka o procesu [78], [79], [80]. Postupak se prepoznaje kao suvremena metoda za analizu sposobnosti procesa preko različitih indeksa sposobnosti. Prema definiciji, sposoban je onaj proces koji može proizvoditi jedinice (dijelove) unutar zahtijevanih granica (granica specifikacije). Proces je sposoban ako je raspon zahtjeva veći ili jednak od raspona procesa. To je ujedno i temeljni uvjet sposobnosti procesa. Raspon zahtjeva, odnosno tolerancijsko područje T je područje između gornje (USL) i donje granice zahtjeva (LSL), odnosno $T = USL - LSL$.

Raspon procesa podrazumijeva područje unutar ± 3 standardna odstupanja (6σ) u odnosu na sredinu procesa (99,73 % površine ispod krivulje normalne raspodjele kojom se aproksimira proces). Stoga temeljni uvjet sposobnosti procesa je: $T \geq 6\sigma$.

Ocjena sposobnosti procesa odgovara na pitanje treba li poboljšati proces. Ako je odgovor potvrđan, postavlja se pitanje za koliko ga treba poboljšati. Ova se analiza svodi na razmatranje uzroka varijabilnosti procesa, budući da se u svakom procesu pojavljuje određeni stupanj varijabilnosti iz slučajnih ili posebnih uzroka. Ocjenom sposobnosti procesa mjeri se učinkovitost i efikasnost procesa u slučaju nepostojanja posebnih uzroka varijacija, dakle u slučaju kada je proces u stanju statističke kontrole. Kad je proces pod kontrolom bit će manja vjerojatnost da promatrani parametri procesa izađu izvan okvira kontrolnih granica. To će biti tako zbog toga jer se na proces može djelovati već u trenutku kada se pojave naznake da bi mogao izaći izvan kontrole, odnosno izvan specificiranih kontrolnih granica. Također treba osigurati ne samo da je proces pod kontrolom, već i da je ispravno centriran u odnosu na

definiranu i praćenu karakteristiku proizvoda ili nekog njegovog parametra. Prije ocjene sposobnosti procesa potrebno je izabrati kritični parametar ili promjenjivu veličinu koja će se kontrolirati. To je veličina koja se mora uklopiti u zadane tolerancije, npr. dimenzija neke pozicije ili bilo koja druga veličina. Kad se odabere kritični parametar, može se pristupiti prikupljanju rezultata mjerenja. Kritični parametar treba biti mjeren što preciznijim mjerilom s klasom točnosti većom od veličine tolerancije. U suprotnom, proces mjerenja će biti uzrok pojave varijacija na konkretnom parametru. Najbolje je prikupljati što više podataka tijekom dužeg vremenskog perioda. Tako se s većom pouzdanošću dobiva ocjena sposobnosti procesa jer se zasniva na velikom uzorku.

Indeksi sposobnosti procesa

Sposobnost procesa procjenjuje se računanjem tzv. indeksa sposobnosti procesa [81], [82]. Računanje i pravilna interpretacija indeksa sposobnosti procesa temelji se na sljedećim pretpostavkama:

- raspodjela podataka se može aproksimirati normalnom raspodjelom,
- proces koji se razmatra je stabilan i bez značajnih uzroka varijacija (proces je „pod kontrolom“),
- pouzdana procjena sposobnosti procesa može se donijeti samo temeljem praćenja procesa primjenom odgovarajuće kontrolne karte i nakon dovođenja procesa u stanje statističke kontrole.

Ako proces nije „pod kontrolom“ računanje indeksa sposobnosti je formalnost i zavaravanje. Otklanjanjem uzroka značajnih varijacija u procesu i dovođenjem sredine procesa u okoliš ciljane vrijednosti ima smisla procjenjivati njegovu sposobnost. Uvažavajući vrijeme odvijanja procesa procjenjivanje sposobnosti (pripadajući indeksi) može pripadati jednoj od slijedeće tri kategorije:

1. Sposobnost procesa u dužem vremenskom razdoblju (engl. *Long–Term Process Capability*)

2. Preliminarna sposobnost procesa (engl. *Preliminary Process Capability*)
3. Sposobnost u kratkom vremenskom razdoblju (engl. *Short-Term Capability*)

Sposobnost procesa u dužem vremenskom periodu

Indeksi sposobnosti procesa računaju se nakon odvijanja procesa tijekom razložno dugog vremenskog razdoblja u kojem su se mogle pojaviti sve moguće varijacije procesa [83]. Preporuka je 20 proizvodnih dana [83].

Procijenjeno standardno odstupanje naziva se „standardno odstupanje iz uzorka“ ili „unutrašnje standardno odstupanje“. Vrijednost ovog indeksa pokazuje može li proces biti sposoban. Što je iznos indeksa veći, to je rasipanje procesa manje. Njegove vrijednosti se kreću oko nule do vrlo velikih pozitivnih brojeva. Što je vrijednost indeksa veća, to je manje rasipanje procesa. Teorijski je proces sposoban ako je $C_p \geq 1$. Sve dok je srednja vrijednost rezultata mjerenja jednaka centralnoj točki tolerancije, može se komentirati i povezati C_p i preciznost procesa. Nedostatak ovog indeksa je u tome što zanemaruje sredinu procesa, te se u slučaju loše centriranosti procesa može doći do pogrešnog zaključka.

Različite tvrtke usvajaju za svoje procese različite kritične vrijednosti C_p . Mnogi japanski proizvođači orijentiraju se na vrijednosti $C_p = 1,33$, što odgovara takvoj situaciji kada interval $\pm 3\sigma$ zauzima 75% od polja dopuštenog odstupanja. Neke tvrtke u razvijenim zemljama danas ovu vrijednost podižu na 1,67, odnosno na $C_p \geq 2$. Iznos indeksa C_p ukazuje na potencijalnu sposobnost procesa koja se uz raspoložive resurse (strojevi, radnici, materijali i dr.) možda može postići. Drugim riječima ovim indeksom su obuhvaćene samo slučajne, procesu svojstvene varijacije. Vrijednost indeksa tijekom dužeg vremenskog razdoblja ima malu varijabilnost bez obzira na pomake u procesu, trendove.

Preliminarna sposobnost procesa

Preliminarno procjenjivanje sposobnosti procesa provodi se na njegovom početku ili nakon kratkog praćenja procesa [84].

Preporuka je da se razmatra uzorak od najmanje 100 jedinica ili kontrolna karta s najmanje 20 uzoraka, sve iz razloga za primjenu indeksa sposobnosti procesa [85],[86], [87].

Preliminarno procjenjivanje sposobnosti procesa provodi se na njegovom početku ili nakon kratkog praćenja procesa. Preporuka je da se razmatra uzorak od najmanje 100 jedinica ili kontrolna karta s najmanje 20 uzoraka.

Razlozi za primjenu indeksa sposobnosti procesa

Sve veća primjena indeksa sposobnosti procesa u vodećim poduzećima u svijetu može se pojasniti na sljedeći način:

1. Razvoj suvremenog pristupa upravljanju kvalitetom sve više u prvi plan stavlja probleme varijabilnosti konkretnih vrijednosti, tj. odstupanja parametara proizvoda od zadanih vrijednosti. U suvremenom svijetu ovo je glavni uvjet konkurentne sposobnosti, a pokazatelji sposobnosti procesa služe kao prikladna mjera varijabilnosti procesa.
2. Inzistiranje na certifikaciji i atestiranju proizvoda zahtijeva uvođenje kontrole kvalitete.
3. Indeksi sposobnosti procesa su prikladni za suvremeni audit procesa, tj. za periodičku provjeru usklađenosti nekog procesa s definiranim zahtjevima.
4. Provjera sredstava u eksploataciji, njihovo podešavanje, kontrola, održavanje i dr. zahtijeva jednostavne kvantitativne pokazatelje stabilnosti karakteristika kroz određeni vremenski period, za što su također veoma prikladni indeksi sposobnosti procesa.
5. Indeksi sposobnosti procesa prikladni su za praćenje, izbor i ocjenu dobavljača, a pomoću njih se mogu postavljati zahtjevi dobavljačima i tako se stimulira njihov razvoj.
6. Istu ulogu mogu imati indeksi sposobnosti procesa pri interakciji s korisnicima i kupcima. Danas je sve teže prodati proizvode za koje se ne znaju indeksi sposobnosti procesa proizvodnje.
7. Indeksi sposobnosti procesa su odlično sredstvo za kontrolu stanja tehnoloških procesa i prikladna mjera za njihovo poboljšanje.

8. Možda je jedna od najvažnijih osobina indeksa sposobnosti procesa što omogućuje svim sudionicima u procesu (od dobavljača do kupca, od radnika do menadžera) da o problemima kvalitete govore istim jezikom, što je neophodan uvjet za dostizanje suvremene kvalitete proizvoda.
9. Kod indeksa sposobnosti procesa postoje i nedostaci. Navode se dva najvažnija. To je prije svega jednostavno usklađivanje sa zahtjevima prema određenoj vrijednosti indeksa, jednostavnom izmjenom vrijednosti USL i LSL u tehničkoj dokumentaciji, bez aktivnosti u stvarnoj proizvodnji. Proizvoljno određivanje i korigiranje tolerancije je najveći problem primjene ovih indeksa. Tolerancija se izračunava ili određuje na osnovi varijance. Tolerancija se mijenja samo ako se u procesima mijenjaju parametri (npr. broj ljudi, novi stroj i dr.) jer se smanjuje varijanca, što automatski utječe na smanjenje tolerancije. Postoji mogućnost da se ne primijete ozbiljni nedostaci proizvoda, oslanjajući se na visoke vrijednosti indeksa sposobnosti procesa u slučaju nepotpunog razumijevanja dopuštenih odstupanja, na kojima se zasniva njihova točna primjena.

Općenito, poboljšanje kvalitete proizvoda ili usluge moguće je postići unapređenjem procesa koji može biti učinkovitiji pomoću statističke kontrole kvalitete. Ista rabi statističku analizu u cilju praćenja, kontrole i neprekidnoga poboljšavanja procesa. Niska proizvodnost, proizvodi koji ne zadovoljavaju potrebe tržišta, oštećeni proizvodi i drugo rezultat su varijacija u procesu. Statistička kontrola procesa unapređuje proizvodni proces tako što smanjuje uzroke varijacije u njima. Kontrolne karte, kao inženjersko – matematičko sredstvo, predstavljaju pogodan alat za ostvarenje ciljeva statističke kontrole kvalitete. Optimalnom primjenom kontrolnih karata osigurava se konstantno praćenje procesa, usmjeravanje ka željenom toku i poduzimanje eventualnih korektivnih mjera. Trend mjernih podataka nastaje zbog poremećaja u proizvodnom procesu. Procesi s izraženim trendom podataka ne slijede normalnu razdiobu te je očigledno da će u izvjesnom trenutku izaći iz granica specifikacije. Kako se to ne bi dogodilo rade se stalne korekcije kojima se proces „vraća“ u željeno područje unutar granica specifikacije. Postupak procjenjivanja sposobnosti takvih procesa je drukčiji nego kod procesa koji slijede normalnu razdiobu. Zbog trenda podataka sposobnost takvog procesa će se

mijenjati u vremenu. Ideja je pronaći optimalno vrijeme korekcije za koje bi indeks sposobnosti procesa imao zadovoljavajuću razinu. Nedostatak regresijske kontrolne karte je da ako povezanost između dvije varijable koje se žele promatrati nije dovoljno jaka, zbog slabe povezanosti regresijska analiza i regresijski model neće biti adekvatni te se neće moći konstruirati adekvatna regresijska kontrolna karta. Kontrolna karta je „slika“ procesa koju treba inženjerski promatrati, utvrditi anomalije ako postoje, ocijeniti koje elemente (parametre) procesa treba pozornije pratiti i stalno tražiti i otklanjati uzroke statističkih pomaka procesa. Na grafikonu Shewardove kontrolne karte na vodoravnoj osi se prikazuje vrijeme, a na vertikalnoj karakteristike dobivene procesom kontrole (pojedinačna mjerenja ili statistika, kao što je aritmetička sredina ili interval varijacije). Kontrolne granice omogućavaju provjeru stabilnosti procesa, odnosno ukazuju na prisutnost posebnih uzroka. Grafikoni se obično konstruiraju pomoću 20–30 početnih uzoraka, od kojih svaki sadrži pet stavki za koje se pretpostavlja da će se pojaviti prilikom slučajnog uzorkovanja. U praksi je često potrebno dati odgovarajuće grafičke prikaze za svako pojedinačno mjerenje.

Histogram

Histogram je alat koji pomaže da se brzo uoči tip raspodjele za uzorke koji sadrže veliki broj podataka. Izradi histograma prethodi: izračunavanje raspona populacije, određivanje intervala razreda, izrada tablica frekvencija, određivanje granica razreda, izračunavanje središta razreda i određivanje frekvencija prebrojavanjem uzorka [87a]. Na osnovu ovih podataka crta se histogram. Na osnovu izgleda histograma donose se zaključci o statističkoj prirodi populacije.

Histogrami su poznati iz matematičke statistike i imaju primjenu u raznim područjima planiranja u građevinarstvu (dinamički planovi angažiranja radne snage i finansijskih sredstava, i sl).

Pareto dijagram

U procesima unapređenja kvalitete Pareto metoda se primjenjuje u područjima upravljanja, marketinga, razvoja, komercijalnih poslova, proizvodnje, financijama, općih

poslova, logistike [88]. Pareto je grafička metoda za analizu pojava (utjecajnih veličina sistema; grešaka, uzroka, uzročnika i sličnih problema; količinskih, masenih, vrijednosnih i drugih karakterističnih veličina procesa rada) u smislu:

- Rangiranja veličina/pojaва koje se analiziraju prema stupnju značajnosti, na osnovu utvrđenih kriterija,
- Utvrđivanja kritičnih područja promatranih veličina/pojaва i
- Usmeravanje napora na postojeća, kritična područja u cilju efikasnijeg rješavanja problema odnosno koncentracije rada na područja koja daju veće učešće u ostvarivanju efekata.

To je oblik stupčastog dijagrama koji teži pronalaženju najznačajnijih čimbenika neke situacije. Temelji se na ideji da nekoliko uzročnika daje veliku većinu varijacija. Općenito pravilo glasi da je oko 20% uzročnika odgovorno za 80% varijacija. Rabi se za traženje pravilnosti u varijacijama tijekom vremena radi dobivanja slike o napretku koji se ostvaruje u nastojanjima koja se odnose na poboljšavanje kvalitete. Tako je moguće utvrditi negativne trendove.

Dijagram raspršenja

Međusoban odnos između dvije varijable, grafički se može prikazati pomoću dvodimenzionalnog grafa, tzv. *scatter dijagram* (dijagrama raspršenja ili raspršnog dijagrama) [89], [90].


Vrijednosti jedne varijable prikazane su na x osi, a druge na y osi dijagrama. Točke presjeka kreću se oko određenog pravca koji se naziva linija regresije. Što su točke bliže pravcu, korelacija je veća. Što su točke raspršenije korelacija je manja. U praksi je vizualno vrlo teško, osim u slučaju »savršene« korelacije odrediti stupanj povezanosti između varijabli. Ovisno o međusobnom odnosu dvaju varijabli među kojima postoji korelacija, ona može biti linearna ili nelinearna. Kod linearne korelacije, točke su grupirane oko pravca. Kod nelinearne korelacije, točke su grupirane oko neke druge krivulje.

Dvije varijable koje se promatraju s ciljem utvrđivanja njihove korelacijske povezanosti mogu biti u četiri različita odnosa:

1. kada mala vrijednost jedne varijable odgovara maloj vrijednosti druge varijable, kao i kada velika vrijednost jedne varijable odgovara velikoj vrijednosti druge varijable, radi se o pozitivnoj korelaciji.
2. kada mala vrijednost jedne varijable odgovara velikoj vrijednosti druge varijable i obratno, radi se o negativnoj korelaciji.
3. kada vrijednost jedne varijable u nekim intervalima odgovara maloj vrijednosti druge varijable, a u drugim intervalima velikoj vrijednosti, radi se o *nemonotonoj korelaciji*. Ako se korelacija više nego jednom mijenja od pozitivne prema negativnoj, takva korelacija naziva se *ciklička korelacija*.
4. kada se na osnovi vrijednosti jedne varijable ne može zaključiti ništa o vrijednosti druge varijable, tada *korelacija ne postoji*. Točke u takvom grafu su raspršene.

Potpuno upravljanje kvalitetom

Tri su razine u razvoju sustava kvalitete: kontrola kvalitete, osiguranje kvalitete i potpuno upravljanje kvalitetom (engl. Total Quality Management – TQM), [91], kako je to prikazano na slici 3.2.[92], [93].



Slika 3.2 Razine kvalitete: od kontrole kvalitete do TQM-a

Najniža razina je **Kontrola kvalitete– QC** (engl. *Quality Control*), karakterizira je odvajanje dobrih od loših proizvoda na ulaznoj, međufaznoj i završnoj kontroli.

Viša razina je **Osiguranje kvalitete – QA** (engl. *Quality Assurance*), karakterizira je: prijelaz u organizaciji za kvalitetu uključivanjem svih funkcija poduzeća na osiguranje kvalitete, uvođenje politike kvalitete u organizaciji i primjena međunarodnih normi kao što je to na primjer norma ISO 9000, odnosno ISO 90003 [149].

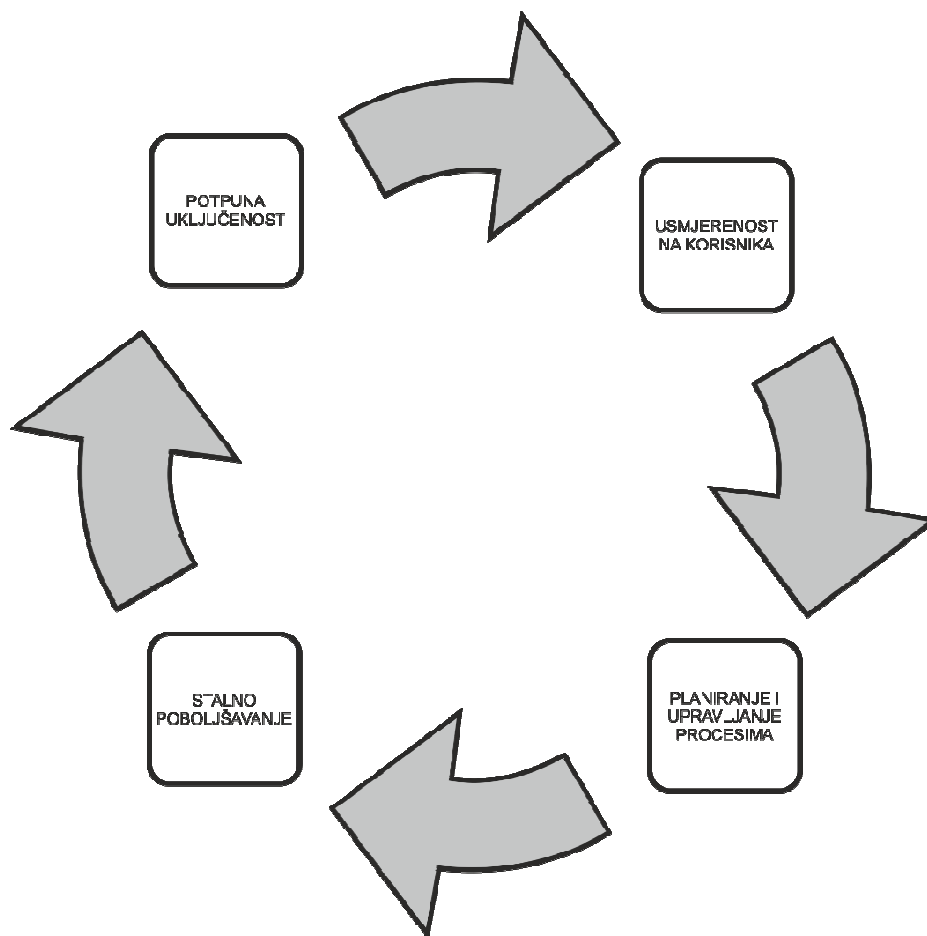
Najviša razina je **Potpuno upravljanje kvalitetom – TQM** (engl. *Total Quality Management*), što znači potpuno uključivanje svih funkcija i svih zaposlenih u poduzeću, dobavljača i kupaca na ostvarivanju visoke kvalitete uz najniže troškove.

Načela koncepta TQM

Koncept TQM se temelji na nekoliko načela:

1. Nužno je izravno sudjelovanje posloводства – najviše rukovodstvo poduzeća treba svojim djelovanjem dokazati deklarirana stajališta u vezi kvalitete, s obzirom da sve aktivnosti započinju s vrha nadalje;
2. Potreban je timski rad – jer tim, pokazalo se, nalazi brža i bolja rješenja od pojedinaca;
3. Nužno je sudjelovanje svih zaposlenih – postizanje kvalitete je zadatak svih zaposlenih;
4. Nužno je školovanje svih zaposlenih – školovanjem za kvalitetu treba provesti od svih razina rukovodstva do svih zaposlenih;
5. Traži se sudjelovanje kupaca – povratna informacija kupca bitna je za poboljšanje usluga ili proizvoda;
6. Nužno je stalno usavršavanje kvalitete – poznavanje tehnika usavršavanja kvalitete omogućavaju provođenje usavršavanja;
7. Nužno je stalno održavanje i preispitivanje normi – norme stalno treba ažurirati kako bi se usuglasile sa stalno višim zahtjevima za kvalitetom.

Danas se kvaliteta ne shvaća toliko kao održavanje zadane kvalitete, nego više kao krug njezina stalnoga poboljšavanja i održavanja.



Slika 3.3. Model potpunog upravljanja kvalitetom [61].

Model potpunog upravljanje kvalitetom je prikazan na slici 3.3, uključuje planiranje i upravljanje procesima, stalno poboljšavanje procesa i potpunu uključenost i usmjerenost na korisnika.

TQM podrazumijeva potpuno ovladavanje problematikom kvalitete za svakog tko se bavi proizvodnjom.

Temelj za uspješno unapređenje kvalitete u potpunom upravljanju kvalitetom predstavlja PDCA (engl. *Plan – Do – Check – Act*) ciklus, tj. ciklus planiraj- provedi- provjeri- djeluj [94]. PDCA je dinamičan ciklus koji se može razviti u svakom od procesa, ali i u sveukupnim procesima u

cjelini. Ciklus je u tijesnoj vezi s planiranjem, primjenom, upravljanjem te stalnim poboljšavanjem kvalitete procesa [61].

3.4. Materijalni podsustav

3.4.1. Jedinični proizvodni procesi


Proizvodnja uključuje pretvorbu sirovine obično dobavljene u obliku jednostavnih ili bezobličnih formi, u konačni proizvod specifičnog oblika, strukture i svojstava koja ispunjavaju dane zahtjeve korisnika. Ova pretvorba u konačni proizvod postiže se uporabom vrlo različitih procesa koji primjenom energije proizvode kontrolirane promjene u svojstvima i strukturi obradnog materijala. Energija primijenjena za obradu može po svojoj prirodi biti mehanička, toplinska, električna ili kemijska. Rezultat obrade podrazumijeva zadovoljavanje funkcijskih zahtjeva koji se određuju u etapi projektiranja proizvoda.

Nekada su se projektiranje, tehnologija i proizvodnja često tretirali kao neovisne inženjerske specijalnosti. Međutim, današnja proizvodnja mora biti cjenovno učinkovita i proizvod na vrijeme na raspolaganju [95]. Ovo zahtijeva da svatko uključen u cjelovit proizvodni ciklus radi zajedno i istodobno osigurava funkcionalnost proizvoda tako da isti bude proizveden učinkovito, lako održavljiv i oporabiv [96]. Ovo identificira velike mogućnosti poboljšanja procesa proizvodnje te velika buduća suradnja različitih inženjersko-proizvodnih timova.

Proizvodnja proizvoda ili neke njegove sastavnice-komponente obično zahtijeva određeni broj slijednih procesa. Na primjer početni proces može biti lijevanje, kojim se dobiva odgovarajući oblik. Zatim može slijediti strojna obrada rezanjem, tokarenjem ili glodanjem kako bi se odljev približio konačno traženom obliku proizvoda ili komponente. Konačni proces može biti površinska obrada u cilju boljeg očuvanja proizvoda, npr. površinskom zaštitom, eloksiranjem ili bojanjem. Svaka od ovih operacija: lijevanje, strojna obrada i površinska zaštita se mogu smatrati jediničnim proizvodnim procesom. U ovom ćemo se dijelu iz pragmatičnih razloga na njih pozivati kao na „jedinične procese“. To su oni pojedinačni koraci zahtijevani za

proizvodnju konačnog proizvoda pretvorbom sirovine koji dodaju dodatnu vrijednost obratku kako postupno postaje konačni proizvod.

Povezani tijek informacije i materijala u jediničnom procesu prikazan je slikom 3.4. Sirovina ili komponente iz prethodne jedinice su ulaz. Izlaz su dijelovi koji su korak bliže konačnom proizvodu te utjecaj što ga proizvodnja u jedinici čini na okoliš, poput onečišćenja česticama ili bukom. Informacijski ulaz i upravljački signali za jedinični proces uključuju proizvodne podatke, procesnu informaciju i postupke vođenja jedinice. Zahtjevi na resurse odnose se na takve pozicija kao što su proizvodna oprema, energija i ljudski resursi.




Slika 3.4. Jedinični proces: tijek informacije te materijala ili komponenti; resursni zahtjevi [97]

Jedinični proces se smatra optimiran kada se dodana vrijednost u smislu tražene promjene strukture i svojstava očituje na obratku na cjenovno najučinkovitiji način promatrano sa stajališta cjelovitog proizvodnog sustava. Ovo uključuje minimalizaciju čimbenika poput potroška energije, generiranja škarta, cijene rada, i zahtjeva na kapital uloženi u strojeve. Dodatno se zahtjeva brzi odziv na potrebe kupaca i sigurnost radnog okoliša. Slijedni jedinični procesi poznati i kao procesni lanci uključuju cjenovne čimbenike koji mogu rezultirati iz potrebe za međufaznim doradama i popravcima za bolju učinkovitost proizvodnje. Opća

definicija prema tome govori o minimalizaciji troškova ulaznih i izlaznih resursa po jedinice proizvoda.

Budući da u svakom pojedinom tipu obrade u jediničnom procesu postoje stotine i stotine inačica, kao npr. kod zavarivanja, potrebno je zbog dovoljne općenitosti navesti da se koristi model koji identificira pet komponenti zajedničkih svim procesnim jedinicama, slika 3.5 [97].

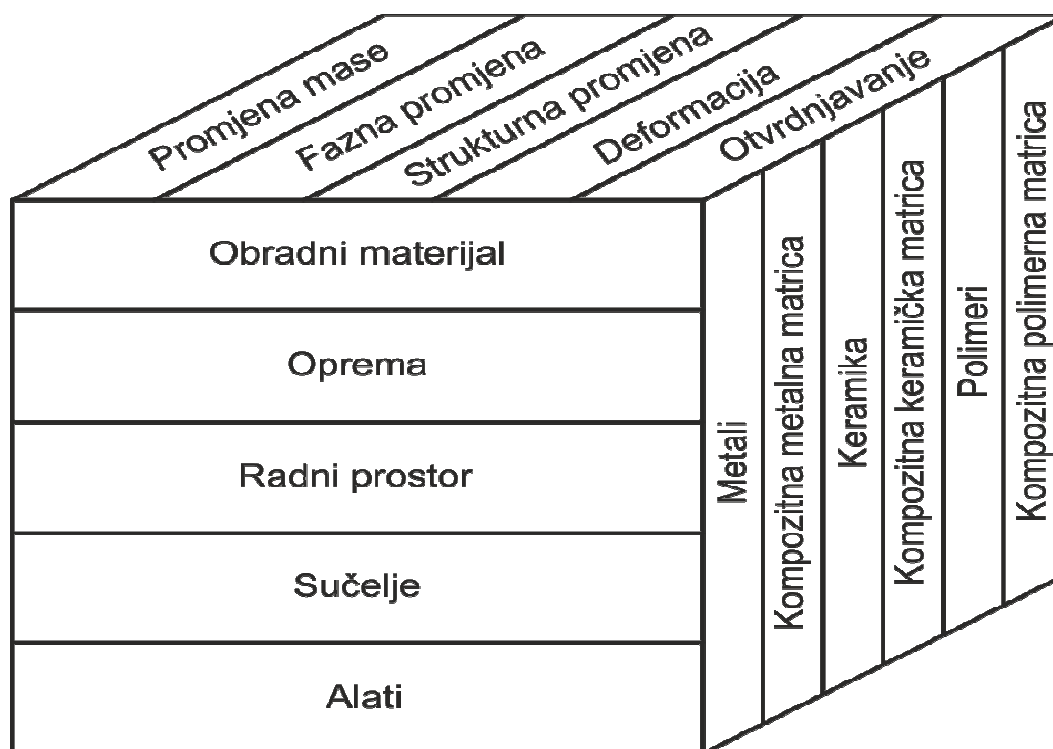


Slika 3.5. Model jedinične procesne proizvodnje

Energija se dobavlja obratku s pomoću procesne opreme i alata i prenosi se na obradak u zoni sučeljavanja alata i obratka. Sučelje često sadrži medij poput rashladne tekućine ili pročištača. Specifične se promjene strukture obratka obično se događaju na ograničenom području obratka označenom kao radno područje. Tako npr. grupa procesa okvirno nazvana strojna obrada uključuje više radnih operacija poput tokarenja, glodanja, bušenja, blanjanja i slično, te opremom s različitim stupnjevima slobode gibanja, različitim brzinama privoda i pričvršćenja obratka te različitim stupnjevima strojne geometrije i njene čvrstoće te raznim medijima za čišćenje i hlađenje obratka i alata.

3.4.2. Porodice jediničnih procesa

Taksonomija jediničnih procesa uključuje pet glavnih porodica procesa: promjenama mase, faznim promjenama, strukturnim promjenama, deformacijama i očvršćivanjem. Ovi su procesi primjenjivi na cijeli opseg obradnih materijala: kovina, polimera, keramika i kompozitnih materijala [97]. Konačni rezultat analize je trodimenzijski prikaz koji se sastoji od procesnih komponenti, procesnih porodica i materijala. Uporabom te koncizne sheme dobiva se uvid u nekoliko područja znanstvenog i tehnološkog znanja koje omogućuje projektiranje i radne operacije jednake za sve jedinične procese. Ova se područja smatraju područjima dostupne tehnologije, slika 3.6 [97].



Slika 3.6. Porodice jediničnih procesa prema komponentama, materijalima i procesnim obradama [97]

Široko područje jediničnih procesa, tj. strojna obrada, kovanje, lijevanje, injekcijsko prešanje uključuje podjednako različite grupe opreme, dizajne alata, materijala sučelja i radnog područja. Procesna oprema može pripadati grupi mehaničkih, termičkih, kemijskih, fotoničkih i električkih uređaja i opreme te njihovim grupnim kombinacijama. Elementi alatnih rješenja uključuju rezne alate, sredstva za glodanje, kalupe, lijevne i otisne obrasce, elektrode, laserske naprave. Sučeljni materijali tipični za jedinične procese su rashladne i čistačke tekućine, izolatori, elektroliti, hidrauličke tekućine i plinovi. Operativni mehanizmi u radnom području jediničnog procesa uključuju deformaciju, otvrdnjavanje, lomljenje, provodljivost, odvodljivost, radijaciju, difuziju, erodiranje, isparavanje, topljenje, mikrostrukturne promjene, fazne prijelaze, kemijske reakcije i mnoge druge mehanizme. Prikaz pet jediničnih procesa za šest proizvodnih jedinica dan je tablicom 3.1

Tablica 3.1. Primjeri pet jediničnih procesnih komponenti

Jedinični proces	Oprema	Obradni materijal	Uobičajen alat	Uobičajeno sučelje	Primarni obradni postupak
tokarenje	tokarski stroj	štapni oblik	točkasti kontakt	tokarska tekućina	Deformacija, lom
površinska obrada	peć	komad	atmosfera	difuzija	fazna promjena
lijevanje	peć	otopina	kalup	sredstvo za opuštanje	ukrućivanje
kovanje	preša	predoblik	kalup	čišćenje	deformacija
sinteriranje	preša	prašak	kalup	sredstvo za konsolidaciju	deformacija
fuzijsko zavarivanje	energetski izvor	obradak	luk	lučna plazma	promjena faze

Na svako od pet navedenih komponenti: oprema, obradak, alat, sučelje i radno područje utječe druga procesna komponenta. Tako na primjer uvjeti sučelja mogu upravljati prijenosom energije iz opreme u radno područje te tako utjecati na lokalizaciju i uniformnost promjene strukture i oblika obratka. Pri strojnoj obradi mogu promjene ili učinkovitost termičkog

ponašanja rashladne tekućine djelovati na termičku distorziju obratka ili opreme rezultirajući u gubitku preciznosti obrade što se očituje kao lošija kvaliteta proizvoda [98].

Većina procesa uključuju više mehanizama radnih područja, s time da jedan mehanizam dominira drugima, u jednom trenutku obrade. Tako pri laserskom bušenju ili rezanju prvo nastaje porast temperature obratka na „napadnutoj površini“ da bi se zatim nametnuo proces fazne promjene, pa isparavanja itd. Kao rezultat toga moguće su varijacije u kvaliteti rezanja, odnosno bušenja, jer ti prijelazi ne moraju biti kontinuirani niti potpuno jednaki. Upravljanje ovim procesom u smislu postizanja što veće uniformnosti zahtijeva pak smanjenje brzine izvedbe pojedinih operacija ili dijelova operacija dodatnim nadzorom u tijeku izvođenja bušenja, odnosno rezanja. Kod promjene obratka ovo zahtijeva pažljivu pripremu operacije kako ne bi došlo i do varijacija u mikrostrukтури obratka.

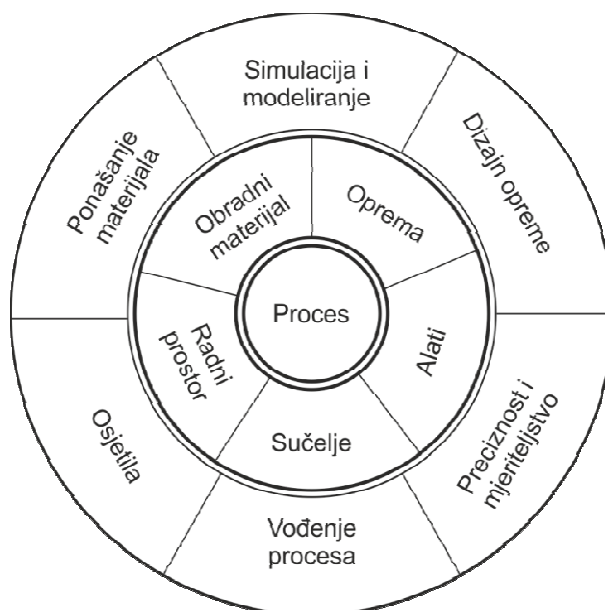
3.4.3. Taksonomija jediničnih proizvodnih procesa, potporni postupci

Budući da postoji nekoliko stotina pojedinačnih jediničnih proizvodnih procesa koji se koriste u komercijalnoj industrijskoj proizvodnji, za svako detaljnije raspravljanje nužno je klasificirati ih uporabom nekih zajedničkih osobina [99]. Relevantna tehnička literatura nudi veliki broj ovakvih klasifikacija, no za potrebe ovog rada orijentirat ćemo se na fizikalne procese koji mijenjaju konfiguraciju ili strukturu materijala tijekom obrade. Prema ovoj taksonomiji razlikujemo pet porodica fizikalnih procesa:

- a) Procesi s promjenom mase odstranjenjem ili dodavanjem materijala mehaničkim, električkim ili kemijskim putem; ovo su klasični procesi poput galvanizacije, strojne obrade tokarenjem ili glodanjem ili manje konvencionalni postupci poput elektrolučne obrade ili elektrokemijske obrade materijala
- b) Procesi promjene faza kojim se obratci u krutom obliku iz tekuće ili plinovite faze; lijevanje kovina, infiltracija kompozitnih materijala te injekcijsko prešanje polimera primjeri su iz ove porodice operacije

- c) Procesi promjene strukture mijenjaju mikrostrukturu obratka ili u cjelini ili na lokaliziranim područjima odnosno na površini; primjeri su toplinski procesi i postupci otvrdnjavanje površina, te procesi s faznim promjenama poput laserskih obradnih procesa.
- d) Deformacijski procesi mijenjaju oblik krutog obratka bez promjene mase ili sastava. Klasični procesi u obradi metala su kovanje i valjanje, te izrada folija dubokim vučenjem i glačanjem.
- e) Konsolidacijski procesi kombiniraju materijale poput čestica, niti ili čvrstih fragmenata za tvorbu dijela ili komponente. Metalurgija praškastih materijala, keramički lijev, kompozitno prešanje matričnih polimera su primjeri konsolidacijskih procesa. Procesi sljepljivanja poput zavarivanja i lemljenja također spadaju u ovu obitelj procesa.

Istraživanje mogućih poboljšanja jediničnih procesa započinje od današnjeg stanja tehnologije te propituje: mogućnost veće ekonomičnosti procesne jedinice, na primjer smanjenjem škarta, ili bazičnim pojednostavljenjem procesa, ubrzanjem procesa inovacije iz razvojnog do proizvodnog stupnja, smanjenjem utjecaja na okoliš, što se opet postiže i smanjenjem škarta, primjenjivost na druge vrste materijala i slično tome.



Slika 3.7. Komponente jediničnog procesa i potporni postupci [100], [97]

Procesi u svakoj porodici jediničnih proizvodnih procesa mogu se primijeniti na bilo koji materijal, kovinu, keramiku ili polimer, ili na kompozitne formacije istih kao matričnih elemenata. Na primjer procesi u konsolidacijskog obitelji jedinica koriste se za proizvodnju metala (kompaktiranjem praha, keramike, pri vrućem prešanju ili pri polimernim kompozitima kod autoklava. Slika 3.7 prikazuje međudjelovanje procesnih obitelji, materijala i procesnih komponenti. Učinkovitost jediničnog procesa u smislu njegovog poboljšanja ovisi o dubokom razumijevanju pet navedenih procesnih komponenti, ali u ovisnosti o šest ključnih tehnika koje omogućuju ispravan dizajn i rad svih procesa. Ovi potporni postupci su: ponašanje obradnog materijala, simulacija i modeliranje procesa, primjena procesnih senzora, procesno vođenje i metrologija te dizajn opreme.

Pri svemu navedenom je dizajn opreme središnja potpora svakog jediničnog procesa. Oprema i s njom povezano opremanje alatima mora biti izvedeno tako da ispunjava posebne funkcije u proizvodnom okolišu. Dodatno su presudni čimbenici poput cijene i proizvodnog ciklusa, održavanje, fleksibilnost uporabe, proizvodnost, kvaliteta proizvoda, te iskoristivost.

Provodivost inovativnog dizajna opreme može voditi k dramatičnim poboljšanjima jediničnih procesa.

Navedenih šest potpornih tehnika nisu međusobno nezavisne. Na primjer, dizajn procesne opreme jako ovisi o razumijevanju procesne preciznosti i mjeriteljstva, koje opet ovise o izboru osjetila i metodologiji vođenja procesa. Ovo je naznačeno na slici 3.7.

3.4.4. Procesni tokovi i integrirana proizvodnja

U većini slučajeva proizvodnja se sastoji od niza slijedno povezanih jediničnih procesa, što se naziva procesni tok. Svaka pojedina procesna jedinica ima izlaz koji je ulaz u neku sljedeću procesnu jedinicu već ovisno o značajkama obradaka. Svaki proizvod se onda može smatrati nositeljem povijesti jediničnog procesa koji mu je prethodio. Svaki konačni proizvod se svojim svojstvima, uključujući i mikrostrukturu, pojavljuje kao zbir iskustava pojedinačnih jediničnih procesa, iskustava koji mogu biti pozitivni ili negativni ili neutralni te tako određuje konačnu kvalitetu i osobine u svojoj primjeni.

Puna dobrobit poboljšanja pojedine proizvodne jedinice koja je dio proizvodnog toka ne mora se realizirati zbog ograničenja u procesima koji joj prethode ili je slijede. Otklanjanje ovih ograničenja ostvaruje dodatne mogućnosti poboljšanja jediničnih procesa. Različite procesne jedinice mogu se izravno povezivati vrlo učinkovito u proizvodni lanac kao integriranu proizvodnju. Primjer jedne takve integrirane proizvodnje dan je u dodatku B. Pri tome se ne mogu izostaviti utjecajni čimbenici na cjelovitu proizvodnju poput zahtjeva uprave za izvrsnošću, sudjelovanja radne snage u postizanju izvrsnosti te modernizacije proizvodnje.

4. KRITIKA POSTOJEĆIH RJEŠENJA SUSTAVA KVALITETE PROIZVODNJE I PRIPADNIH INFORMACIJSKO PROCESNIH OBRAZACA

Sustav kvalitete zahtjeva uvođenje metoda identifikacije mjesta nastanka škarta u danoj industriji. Stoga je sustavski cilj praćenje stanja škarta. Metode osiguranja i kontrole kvalitete za procese sa zamjetnim škartom ne bi trebali pratiti tradicionalne postupke, već se orijentirati na praćenje informacijskih tokova, odnosno informacijskoj makrodinamici postrojenja.

4.1. Metode osiguranja i kontrole kvalitete

Izdvajanjem osiguranja kvalitete procesa pripreme, poput bojanja, pripreme podloge i pripreme smjese u keramičkoj industriji, srž osiguranja kvalitete orijentiran je prema smjenskim podacima proizvodnog procesa, prilog B. Smjensko praćenje podataka omogućuje bolji uvid u procesne varijable i njihovo povezivanje sa smjenskim stanjem škarta.

Tradicionalno, kontrola kvalitete (engl. *Quality control* – QC) se oduvijek provodila procjenom i podešavanjem procesa s pomoću ljudi [101],[102]. Prema autoru Tague [103], postoji nekoliko osnovnih alata kontrole kvalitete, koji uključuju: uzrok-i-posljedica dijagram (engl. *cause-and-effect diagram*) Ishikawa diagram, Shewart-ove kontrolne karte (engl. *Shewart control charts*), kontrolna tablica (engl. *check sheet*), histogram, Pareto karta (engl. *Pareto chart*), raspršeni dijagram (engl. *scatter diagram*) i stratifikacija (slojevitost) (engl. *stratification*).

Ishikawa diagrami (1990) se koriste za prikaz uzroka određenih događaja [104]. Ti dijagrami se poglavito koriste u procesu dizajniranja proizvoda i za preventivu grešaka kvalitete. Glavni nedostatak ove metode je da ona ne razlikuje nužne od dovoljnih uvjeta koji dovode do nekog događaja.

Izradom linijskih karata, koje upućujući na Shewhart-ove kontrolne karte, uvedenih 1924, i slijedeći varijabilnost u tim primjerima, te promatrajući trend ili opadanje kontrole, poduzimaju se aktivnosti kako bi se otkrili uzroci problema [105], [106].

Suvremene tehnike koje su razvijene iz monitoringa kontrolnih karata kao što je to MEWMA [106], [107] mogu se koristiti ako su pravilno uspostavljeni statistički parametri procesa.

Povezanost uzoraka procesnih signala i konačnog kvalitetnog uzorka nije lagano modelirati, zbog mnogih unutarnjih međustanja aktualnog procesa [105], [106], [108], [109].

Signalni uzorak se može definirati kao signalni obrazac koji se javlja manje ili više od očekivanog [110]. Pareto karte su predložene za vizualizaciju te veze [104],[105]. Mjerenje rizika kvalitete pomoću Pareto karata je povoljno, najčešće u razvojnoj fazi kvalitete proizvoda. Problemi kontrole kvalitete tijekom serijske proizvodnje moraju počivati na istraživanju brzih bitnih informacija o ponašanju procesa, mjerenjem relevantnih procesnih signala i konačne kontrole kvalitete proizvoda[111].

U svrhu rješavanja problema procesiranja informacija, primjenjuju se alati umjetne inteligencije kao što su ekspertni sustavi [110], ili umjetne neuronske mreže (engl. *artificial neural networks* - ANNs) [111]. Rezultati koji se odnose na takvim na pravilu – temeljenim sustavima pokazuju:

- 1) naglasak je na proceduri s gotovo direktnim rezultatima, neovisno o faktorima koji mogu biti samo efektivno evaluirani na temelju duljeg vremenskog perioda, vidi npr. greška moda i analiza učinka (engl. *Failure Mode and Effect Analysis* (FMEA)[105], [106].
- 2) problem može evoluirati u situacije koje uključuju višestruke elemente koje treba analizirati i time težiti prema nečem što se općenito referira kao „kombinatorna eksplozija“ u donošenju odluke [112].

Kvaliteta, cijena i vrijeme su važni faktori u konceptima dizajna proizvoda i ograničenom broju opcija prethodnih dizajna [112]. Ovi faktori limitiraju implementaciju ANN-a. Druga stvar s ANN je pouzdanje atributa, jer proizvodni stroj mjeran s istim atributima može proizvesti potpuno drugačije postotke odbijanja [113], [112]. Dodatno, niska interpretativnost rezultata ANN-a može također biti problem. Neovisno o korištenju ekspertnih sustava i ANN-a, kontrola kvalitete kroz tradicionalni menadžment donošenja odluka je temeljena na procjeni financijskih pokazatelja kompanije. Uključivanje indikatora ne-financijskih pokazatelja kao sposobnost proizvodnje, upravljanje ljudskim resursima i odnosi u lanca dobavljača, daju jasniju i mjerodavniju sliku pokazatelja kvalitete [114],[115].

Analiza obuhvata podataka (engl. *Data Envelopment Analysis –DEA*) daje mjerilo osposobljenosti kompanije naspram najboljih proizvođača [116].

Mjerilo performansi (engl. *Benchmarking*) je nepristrana procedura, ali ostavlja kontrolu kvalitete proizvodnje uglavnom neriješenom. Analitički hijerarhijski proces, AHP (engl. *Analytical hierarchy process*, AHP) je razvio Saaty [117], a primijenjen je na neodređene probleme koji uključuju mnogobrojne indikatore. Procedura se često koristila u rješavanju problema koji uključuju rangiranje, selekciju i predikciju odluka [117]. Također postoji metodologija za evaluaciju dinamičkih značajki procesa poduzeća s modelima metrika mjerenja temeljenih na aktivnost-temeljena procjena troškova i aktivnost-temeljen menadžment (engl. *Activity-Based Costing and Activity-Based Management*)[118].

Ove procedure mjere dinamiku procesa za šest vrsta tijekova procesa unutar proizvodnog poduzeća, uključujući tijek aktivnosti, tijek proizvodnih informacija, tijek resursa, tijek troškova, tijek gotovine i tijek profita. Kriterij kvalitete u ovom razmatranju se koristi u sveukupnoj shemi evaluacije troškova bez uzimanja u obzir aktualnu kvalitetu proizvoda.

Može se utvrditi da, iako ekspertni sustavi nisu savršeno rješenje za kontrolu kvalitete (engl. *Quality Control - QC*), oni ipak imaju prednost nad tradicionalnim menadžment-baziranim QC tehnikama odlučivanja. Međutim, ekspertni, normirano-bazirani sustavi ne djeluju dobro u

dinamičkoj okolini koja je uvijek prisutna kod automatiziranih kontrolnih sustava s unaprijed postavljenim strojnim podešenjem. Informacije o onome što se u stvarnosti događa u procesu proizvodnje ostaju skrivene u pravilima ekspertnog sustava i njegovoj bazi znanja, koja može biti samo djelomično točna i nekompletna. Kao posljedica, QC signal može ukazivati na osobine proizvodnje, ali nažalost, samo na općoj razini, jer detalji dinamike proizvodnje se ne mogu obuhvatiti pravilima ekspertnih sustava.

4.2. Pristup kontroli kvalitete temeljen na informacijskom sustavu

Proizvodni sustav je pod kontrolom subjekata koji su inteligentni agenti kao što su to ljudi, roboti i strojevi. Njihova intencija je planirana i kombinirana prema cilju ili proizvodu koji ima određene predefinirane granice kvalitete. Svrhovitost akcija subjekta u proizvodnom sustavu se odražava u:

- 1) karakteristikama krajnjeg proizvoda, njegovu kvalitetu zahtjeva potrošač i obično je definirana određenim normama,
- 2) objektivnim mjerenjima kvalitete provedenih u nekim predodređenim koracima proizvodnog procesa i kao mjera kvalitete krajnjeg proizvoda,
- 3) kontrolnim mjerenjima, koja se odnose na stanja proizvodnog stroja koji odražava buduće stanje proizvoda (npr. dimenzija proizvoda), ili eksperimentalnim indikatorima koji odražavaju procedure proizvodnje u svim njihovim detaljima kao potrebnih karakteristika proizvoda,
- 4) proizvodnim podciljevima, dijelovima proizvodnog procesa pogodnih za provedbu racionalne kontrole dostignutih proizvodnih podciljeva.

Koraci subjekta za dostizanje cilja su prema tome ciljno-orijentirani. U funkcionalnom smislu, orijentacija prema cilju se obavlja kroz niz dobro planiranih koraka koji moraju odgovarati specificiranim normama.

Definicija 1: *svrhovito ponašanje sustava ili teleonomija je zadovoljavajuće ponašanje sustava prema specifičnom cilju.* U najjednostavnijem slučaju ispunjenje cilja se može iskazati

kao dostizanje specifične vrijednosti izlaznog signala sustava. Automatizirani proizvodni sustav je dizajniran primarno da bude svrhovit ili teleonomičan u smislu da kvalitetni signal izlaznog proizvoda odgovara specifičnoj vrijednosti. Prema tome, za dostizanje stupnja na kojem su aktivnosti unutar linije automatske proizvodnje teleonomične, obično se upotrebljavaju QC alati i metode.

Na primjer, temeljni zahtjevi za QC u automatiziranoj proizvodnji keramičkih pločica su iskazani normom ISO – 13006 [119].

Temeljeno na toj normi, i odražavajući zahtjeve menadžmenta i procjenom stanja operatora i strojeva, definiraju se specifični ciljevi, kao što je to postizanje 80 % prve klase keramičkih pločica s manje od 6 % škarta.

Ipak, točna kvantitativna metoda za postizanje teleonomije sustava na svakom koraku procesa ne postoji, iako se svi strojevi automatske proizvodnje mogu podesiti prema specifikacijama proizvođača strojeva. Jedino svojstvo sustava koje se može mjeriti je pouzdanost, tj. broj grešaka proizvodnih strojeva prema jedinici radnog vremena. Druge funkcionalne karakteristike sustava ili proizvoda nisu mjerljive [120].

Zadovoljenje teleonomije sustava se može trasirati standardnim statističkim alatima (npr. ARMA, autokorelacija ili samoovisnost), ali taj pristup trpi od općih ishoda zbog kompleksnih relacija unutar procesa. Također, u mnogim slučajevima, može biti premalo mjerenja za valjani zaključak [121].

Evaluacija kvalitete krajnjeg proizvoda koja ovisi isključivo o mjerenjima procesa mora uključivati adekvatne informacijske mjere za ukazivanje subjekata koji se ne ponašaju prema prihvaćenoj proizvodnoj kulturi ako se proizvodno postrojenje promatra kao informacijski sustav [122].

Kroz sinkronizaciju mjerenja procesa sa određenim QC varijablama, ta informacijska mjerenja trebaju omogućiti objektivnu evaluaciju ponašanja stroj/osoblje tijekom proizvodnje.

Jedna od mogućih informatičkih mjerila koja se odnose na brojčana mjerenja sustava je Shannon-ova informacijska mjera – entropija, koja se koristi za procjenu sadržaja mjerenja entropije. Entropija procesnog signala je mjera njegove varijabilnosti. Ta varijabilnost se može prikazati u broju kategorija mjernih vrijednosti, kao što je predložio Shannon, koristeći izraz [2]:

$$H = - \sum_i P_i \log P_i, \text{ bit} \quad (4.1),$$

gdje je logaritam računat po bazi dva a P_i je vjerojatnost pojave određene kategorije mjernih vrijednosti, koda.

Većina signala u automatskoj proizvodnji ili nema promjene ili ima pravilne promjene od njihove potrebne vrijednosti. Takvo mjerenje se ne može automatski uzeti u obzir za izračun odgovarajuće Shannon-ove entropije zbog očekivanog nedostatka odgovarajuće funkcije distribucije vjerojatnosti.

Dugoročno promatranje takvih signala može doprinijeti funkciji distribucije vjerojatnosti za koju je Shannon-ova mjera entropije održiva [2]; ipak proizvodni gubici zbog produženog prikupljanja informacija su neprihvatljivi [40] i vjerojatno nepogodni za pragmatično otkrivanje QC grešaka. Druga informatička mjerila razvijena specifično za kraće vremenske serije mogu se uzeti u obzir za monitoring kvalitete, kao što je to aproksimativna ili približna entropija [123], ako je ona otpornija na smetnje i nema statističkih zahtjeva.

Bilo koje predloženo informatičko mjerenje za procjenu teleonomije sustava u automatiziranim industrijskim sustavima u svakom koraku procesa mora barem, zadovoljiti sljedeće zahtjeve:

- 1) primjenljivost kratko – vremenskim promjenljivim podacima s proizvoljnom inherentnom distribucijom vrijednosti.
- 2) otpornost na ponavljajuća jednaka mjerenja
- 3) sposobnost fokusiranja na interesantne dijelove procesa koji iskazuju ne – teleonomičko ili destruktivno ponašanje.

- 4) jedinstvenost vrijednosti informacijskih mjera za različite ulaze mjernih uzoraka.
- 5) interpretabilnost rezultata.

U sljedećem poglavlju predlaže se informatička obrada i generiranje procesnih obrazaca temeljenih na modificiranom Carnapovom konceptu entropije [40], koji se naziva proširena tesalacijska entropija.

Potom se prikazuje da to mjerenje zadovoljava pet gore prikazanih zahtjeva i da se mogu kvantificirati informacije na način da se postojeća mjerenja QA službe mogu upotrijebiti za povezivanje dinamike mjerenja procesnih signala s obrascima koje generira QC varijabla u automatiziranom proizvodnom sustavu.

5. EKSPANDIRANA 1D CARNAPOVA ENTROPIJA

5.1. Izračun abecedne entropije vremenski ograničenog procesnog obrasca

Abecedna se entropija izvodi iz dviju teorija: Carnapove jednodimenzijske entropije [38] i matrice razlika diskretnih mjerenja [124]. Carnapova jednodimenzijska entropija bila je originalno predložena kao:

$$CarnEn_{1D} = \sum_{i=1}^N \log_2 \frac{|d_i|}{x_N} \quad (5.1),$$

gdje je $|d_i|$ opseg okoliša točke x_i , x_N je cjelokupno područje mjerenja a N je broj točaka u seriji. Mjera je prilagođena apsolutnom iznosu mjerenja kako bi obuhvatila i granične mjerne iznose područja mjerenja:

$$CEn = -\left(\frac{x_1+x_2}{2x_N} \log_2 \frac{x_1+x_2}{2x_N} + \sum_{i=2}^{N-1} \frac{x_{i+1}-x_{i-1}}{2x_N} \log_2 \frac{x_{i+1}-x_{i-1}}{2x_N} + \frac{x_N-x_{N-1}}{2x_N} \log_2 \frac{x_N-x_{N-1}}{2x_N}\right) \text{ bit}/x_N \quad (5.2).$$

Ovdje je x_i točka smještena na jednodimenzijsku liniju. Ovakav prikaz ne uzima u razmatranje evoluciju sustava, budući da se točke na liniji nužno ne pojavljuju u istom poretku kao i na izvornom signalu.

S teorijske točke gledišta promjene u mjerenjima se mogu izraziti kvalitativno kao pozitivne jedinične promjene (Δ), negativne jedinične promjene ($-\Delta$), ili kao nepostojanje promjene (0), gdje za binarni slučaj vrijedi:

$$\Delta, \text{ ako } x_{i+1} - x_i > \vartheta; -\Delta, \text{ ako } x_{i+1} - x_i < \vartheta \\ s_i = 1, 2, 3 \quad (5.3),$$

gdje je ϑ razina opažaja promjene, koja ovisi o prirodi mjerelog signala. Znakovi L abecede se oblikuju kao moguće kombinacije od $s_i, i = 1..3$. Za tri promjene uzoraka mjernih signala i dani

s_i postoji ukupno 27 mogućih kombinacija označenih kao $L = \{A, B, \dots, Z, AA\}$. Može se pokazati da informacijski sadržaj zasnovan na Carnapovoj entropiji danoj u (5.2) za znakove abecede nije jedinstven za svaki znak abecede tj da neki znakovi abecede imaju isti sadržaj informacije zasnovan na izrazu (5.2). poput znakova B, H, i Q [111].

Abecedna entropija je proširenje Carnapove entropije koja uzima u obzir po četiri uzastopna mjerna signala i obrađuje njihove sve moguće mjerne razlike. Ovo uključuje apsolutni iznos mjernog signala i razlike među svim mjerenjima. Evolucija promjena se zapisuje kako bi se sačuvala trajektorija sustava. Neka je $X = (x_1, x_2, x_3, x_4), x_i \in R$ četvorka slijednih procesnih mjerenja signala. Razmatra se proširenje sadržaja informacije četvorke kojom bi se obuhvatili sadržaji promjena signala između mjerenja čime bi se kvantificirala dinamika sustava. Matrica razlika ove četvorke može se prikazati kao:

$$\begin{bmatrix} d_{1,2}d_{2,3}d_{3,4} \\ \times d_{1,3}d_{2,4} \\ \times \times d_{1,4} \end{bmatrix} \quad (5.4),$$

gdje je $d_{i,j}$ promjena mjernog signala x_i i x_j , a \times stoji za nekorišteni element matrice. Vektor proširenja $(d_{1,2}d_{2,3}d_{3,4}d_{1,3}d_{2,4}d_{1,4})$ kodira sve moguće promjene između četiri uzastopna mjerenja i dodaje informaciju o promjenama drugog i trećeg reda. Abeceda je prikazana na tablici 5.1

Kako bi se očuvala informacija o apsolutnim iznosima mjerenja definira se šestorka kao:

$$Y = (y_1, y_2, y_3, y_4, y_5, y_6), \text{ gdje su: } y_1 = x_1 + d_{1,2} = x_2, y_2 = x_2 + d_{2,3} = x_3, y_3 = x_3 + d_{3,4} = x_4, y_4 = y_3 + d_{1,3}, y_5 = y_4 + d_{2,4}, y_6 = y_5 + d_{1,4}.$$

Budući da nema garancije da su vrijednosti Y dane u uzlaznom poretku, što je nužno za izračun izraza (5.2), navedene se vrijednosti prethodno sortiraju.

Neka je $Z(z_1, z_2, z_3, z_4, z_5, z_6)$ šestorka sortiranih vrijednosti od skupa Y . Abecedna se entropija može izračunati iz četiri uzastopna mjerenja kao:

$$AlEn = -\left(\frac{z_1+z_2}{2z_6} \log_2 \frac{z_1+z_2}{2z_6} + \sum_{i=2}^5 \frac{z_{i+1}+z_{i-1}}{2z_6} \log_2 \frac{z_{i+1}+z_{i-1}}{2z_6} + \frac{z_6-z_5}{2z_6} \log_2 \frac{z_6-z_5}{2z_6}\right), \text{ bit}/z_6$$

(5.5).

Tablica 5.1. Abeceda i kodirane dinamičke promjene signala

Znak	Kodne promjene znaka	Kvalitativno predstavljanje vektora proširenja
A	0 0 0	0 0 0 0 0
B	0 0 +	0 0 + 0 + +
C	0 0 -	0 0 - 0 - -
D	0 + 0	0 + 0 + + +
E	0 - 0	0 - 0 - - -
F	0 + +	0 + + + + +
G	0 - -	0 - - - - -
H	0 + -	0 + - + 0 0
I	0 - +	0 - + - 0 0
J	+ 0 0	+ 0 0 + 0 +
K	- 0 0	- 0 0 - 0 -
L	+ 0 +	+ 0 + + + +
M	+ 0 -	+ 0 - + - 0
N	- 0 -	- 0 - - - -
O	- 0 +	- 0 + - + 0
P	+ + 0	+ + 0 + + +
Q	+ - 0	+ - 0 0 - 0
R	- - 0	- - 0 - - -
S	- + 0	- + 0 0 + 0
T	+ + +	+ + + + + +
U	+ + -	+ + - + 0 +
V	+ - +	+ - + 0 0 +
W	+ - -	+ - - 0 - -
X	- - -	- - - - - -
Y	- - +	- - + - 0 -
Z	- + -	- + - 0 0 -
AA	- + +	- + + 0 + +

Ovaj informacijski sadržaj je jedinstven za svaki znak abecede [111]. Zamijetimo da ukoliko postoje isti iznosi mjernog signala tada se logaritmi u (5.5) ne mogu izračunati. U tom slučaju se logaritmi uzimaju u izračun više puta dok se oni koji sadrže isto mjerenje izostavljaju.

5.2. Osobine abecedne entropije

Očigledno je iz izraza (5.5) da abecedna entropija kvantificira vrlo kratkotrajnu varijabilnost originalne vremenske serije. Najmanji vremenski okvir koji se može analizirati ovom metodom po tome ovisi o načinu uzorkovanja, ali uvijek uključuje četiri mjerenja. Najduži vremenski okvir međutim nije ograničen na samo četiri mjerenja budući da se entropija može računati slijedno za svaku četvorku mjerenja.

Formalno bilo koji signalni segment $\{x_i\}$ može se kodirati u odgovarajući niz $\{L_i\}$ uporabom izraza (5.3), tako da duljina takve znakovne serije bude $|L| = \text{len}(\{L_i\}) = \text{len}(\{x_i\}) - 3$. Brojka 3 označava vremensko zaostajanje izračuna koda i pripadne entropija od početka uzorkovanja.

Abecedna entropija može se izračunati za svaki znak L_i in $\{L_i\}$. Ovo daje seriju znakova abecedne entropije $\{AlphEn_i\}$ koja odgovara znakovima $\{L_i\}$, izračunatim iz (5.5). Iz serije abecednih znakova $\{L_i\}$ i serije abecednih entropija $\{AlphEn_i\}$, mogu se izvlačiti različite statističke osobine. Neke od tih mogu uključivati:

1. Prosječna abecedna entropija po segmentu:

$$AverAlphEn = \frac{\sum_{i=1}^{|L|} AlphEn_i}{|L|} \quad (5.6);$$

2. Varijanca abecedne entropije po segmentu:

$$AlphEnVar = \sqrt{\frac{\sum_{i=1}^{|L|} (AlphEn_i - AverAlphEn)^2}{|L| - 1}} \quad (5.7);$$

3. Maksimalna abecedna entropija po segmentu:

$$MaxAlphEn = \max_i AlphEn_i \quad (5.8);$$

4. Prosječna abecedna entropija za svako slovo u segmentu:

$$AverAlphEn(L_i) = \frac{\sum_{j=1}^{|L_i|} AlphEn_j}{|L_i|}, i = 1..27 \quad (5.9);$$

5. Varijanca abecedne entropije za svako slovo u segmentu:

$$AlphEnVar(L_i) = \sqrt{\frac{\sum_{j=1}^{|L_i|} (AlphEn_j - AverAlphEn(L_i))^2}{|L_i|}}, i = 1..27 \quad (5.10);$$

6. Maksimalna abecedna entropija svakog slova u segmentu:

$$MaxAlphEn(L_i) = \max_j AlphEn_j, j = 1..|L_i|, i = 1..27 \quad (5.11);$$

7. Postojanje nekog slova u segmentu:

$$Postoji(L_j), ako je L_j \in \{L_i\}, j = 1..27 \quad (5.12);$$

8. Učestalost pojave slova u segmentu:

$$Rate(L_j) = freq(L_j)/|L|, L_j \in \{L_i\}, j = 1..27 \quad (5.13).$$

Sva navedena svojstva nisu računarski zahtjevna i mogu se brzo dobiti iz snimanog segmenata različite duljine.

5.3. Teselacijska entropija informacijskih obrazaca kao model procesne dinamike kvalitete izlaznog proizvoda

5.3.1. Tehnički problemi s informacijskim sadržajem signala

Kontrola kvalitete obročnih procesa zasniva se na cjelovitoj obradi i pravilnom tumačenju toka podataka u i iz procesa. U obročnoj proizvodnji prate se podaci o sirovini, međufaznim mjerenjima poluproizvoda, mjerenjima na strojevima i konačno mjerenjima izlazne kvalitete proizvoda. Cilj je smanjenje škarta u proizvodnji. Da bi osigurali dovoljno brzu obradu podataka za ostvarenje cilja potrebno je na vrijeme uočiti možebitne izvore smanjene kvalitete izlaznog proizvoda ili poluproizvoda i odgovarajućim akcijama popraviti izlaznu kvalitetu. Proizvodne linije u modernoj keramičkoj ili komadnoj proizvodnji redovito su visoko automatizirane i/ili se sastoje od niza visoko automatiziranih strojeva koje poslužuju roboti ili robotizirane palete. Proizvodni strojevi i proizvodne linije generiraju signale koji su brojčanog oblika ili se kontrolna mjerenja koje na njima provode radnici kontrole kvalitete iskazuju kao brojčani podaci. Isto tako se i podaci izlazne kvalitete kod visoko proizvodne komadne proizvodnje kakva je proizvodnja keramičkih pločica iskazuju po smjenama u obliku postotka škarta ili postotka određene klase proizvoda u skladu s normom ISO 13006. Tehnički je problem kako povezati brojčane podatke dobivene sa proizvodnih linija i strojeva s cjelovitim podacima izlazne kvalitete kako bi se pravodobno mogao uočiti neki uzročno-posljedični lanac kvarova i djelovati u smislu poboljšanja kvalitete. Prema patentu [125], podaci iz procesa obročne proizvodnje integriranih krugova obrađuju se onako kako su izravno snimljeni korištenjem različitih postupaka dubinske analize podataka (engl. *data mining*). Ovakvim izravnim tumačenjem procesnog mjerenja gubi se informacija o složenom međudjelovanju strojeva i poluproizvoda koja sadržava potpuno tumačenje interakcija svih uzoraka snimljenih signala. Jedino što se ustanovljava to su globalni indikatori mogućih kvarova, što je dostatno samo u etapi planiranja i podešavanja proizvodnje. Stoga je u svrhu cjelovitijeg sagledavanja stanja procesa tijekom rada potrebno provesti širi informacijski obuhvat uzoraka signala i istima pridijeliti odgovarajući informacijski sadržaj. Proširenje informacijskog sadržaja nužno se obavlja na ulaznom skupu podataka s jasnom funkcijom: sačuvati i otkriti što bolje samu prirodu cjelokupne informacije sadržane u procesu.

Prirodu mjerene procesne informacije izražavamo količinom njene entropije, mjerenom u bitovima. Međutim, mjerenja na automatiziranim strojevima ne omogućavaju izražavanje Shannonove mjere entropije budući da 1) ista zahtijeva dovoljno veliki skup podataka za valjanu statističku obradu, a to bi u uvjetima obročne automatizirane proizvodnje dovelo do povećanja škarta, te 2) nepostojanje definirane statističke razdiobe mjerenja budući da je većina mjerenja na automatiziranim strojevima stalna veličina – gotovo konstantna.

5.3.2. Ekspanzija informacijskog sadržaja procesnog signala

Prva razmišljanja o proširenju (ekspanziji) pojavljuju se vrlo rano i uglavnom su vezana uz filozofske spekulacije oko nastanka svemira [126]. Utemeljenjem informacijske teorije počinje se govoriti o vidovima proširenja informacije. Tako Taborsky kaže da je neprekidno širenje informacije ustvari evolucija [127]. Proširenje se osim u teoriji informacije vrlo malo primjenjuje u drugim granama znanosti. Neke metode korištenja proširenja javljaju se u fizici [128], tekstualnim informacijskim sustavima [129], evolucijskim algoritmima [130], i u postupku Meduza [131], [132].

Striktno proširenje mjernih podataka razvojem udesno prikazano je u patentu P20000500A, autora Željka Jagnjića [126], i primijenjeno na kvalitativno modeliranje ciljne funkcije u analizi signala elektrokemijskog mjernog instrumenta [124]. Ono što nedostaje prethodnim radovima je kvantitativna mjera proširenog informacijskog sadržaja procesnih podataka. Stoga se predlaže proširenje teselacijske entropije Carnapovog za jednodimenzijско predstavljanje procesnih signala u cilju utvrđivanja jednoznačne informacije o tijeku proizvodnje.

5.3.3. Opis postupka teselacijske entropije proširenog mjernog signala

5.3.3.1. Abecedna entropija i njena primjena

Abecedna entropija primjenjuje se na analizu industrijskih signala kontrole kvalitete [111]. Ovdje će se zbog preglednosti prikaza izložiti postupak u donekle sažetom obliku.

Izvod abecedne entropije


Abecedna entropija potječe s dva izvora: iz jednodimenzijske Carnapove entropije kao modifikacije Carnapova pristupa [33] i iz matrice razlika diskretnih mjerenja [124]. Carnapova jednodimenzijska entropija je originalno predložena u obliku kao:

$$Carn_{1D} = \sum_{i=1}^N \log_2 \frac{|d_i|}{x_N} \quad (5.14),$$

Gdje je $|d_i|$ područje zauzimanja oko mjerne točke x_i , a N je broj točaka u nizu mjerenja. Mjerenje je prilagođeno tako da mjeri apsolutni iznos i da uzima u obzir mjerne granice, slika 5.1 za vizualni opis granica mjerenja. Odatle je Carnapova jednodimenzijska entropija za opseg mjerenja procesnog signala L jednaka:


$$CarnAd_{1D} = Carn_{1D} = - \left(\frac{x_1+x_2}{2x_N} \log_2 \frac{x_1+x_2}{2x_N} + \sum_{i=2}^{N-1} \frac{x_{i+1}-x_{i-1}}{2x_N} \log_2 \frac{x_{i+1}-x_{i-1}}{2x_N} + \right. \\ \left. + x_N - x_1 - 12x_N \log_2 x_N - x_N - 12x_N \text{bit/L} \right) \quad (5.15),$$

gdje je $L = x_N - x_1$, a x_i je mjerna vrijednost na mjernom pravcu u jednoj dimenziji. Ova prilagodba još uvijek ne uzima u obzir kretanje procesa u vremenu jer se točke na liniji nužno ne poklapaju s vremenskom osi mjerenja. Odatle se pri izračunu entropije gubi informacija o trajektoriji procesnog mjerenja.



Slika 5.1. Elementi izračuna 1D Carnapove entropije

Abecedna entropija je proširenje 1D Carnapove entropije koje uzima u obzir četiri diskretna mjerenja u vremenskoj seriji mjerenja i služi za opis potpunog informacijskog opisa tih četiriju uzastopnih mjerenja. Ovo uključuje apsolutne vrijednosti mjerenih veličina kao i vremenski unaprijedne razlike između svake od mjernih veličina, slika 5.2 .



Slika 5.2. Potpuna ekspanzija četiriju mjerenja M1, M2, M3 i M4, prikazana s osnovnim mjerenjem M1 i šest mjernih razlika

Evolucija mjerenja sadržana je u uzastopnim četvorkama potpuno ekspanziranih unaprijednih razlika mjernih signala. Tako je zbog usmjerenosti prikaza sačuvana ireverzibilnost trajektorija ponašanja mjerne veličine.

S teorijskog stajališta, promjene mjerenja mogu se kvalitativno izraziti kao jedinične pozitivne promjene (Δ), jedinične negativne promjene ($-\Delta$), ili nepostojanje promjene (0), dakle kao ternarno kodiranje, (vidi (5.3) za binarno kodiranje):

$$s_i = \begin{cases} 0, & \text{ako } |x_{i+1} - x_i| \leq \vartheta \\ \Delta, & \text{ako } x_{i+1} - x_i > \vartheta \\ -\Delta, & \text{ako } x_{i+1} - x_i < \vartheta \end{cases} \quad (5.16),$$

gdje je ϑ prag neosjetljivosti na promjenu, ovisan o prirodi vremenske serije podataka. Slova abecede S oblikuje se mogućim kombinacijama $s_i, i = 1..3$. Postoji skup S od ukupno 27 mogućih kombinacija od četiri elementa mjerenja s tri promjene označenim sa $L = \{A, B, \dots, Z, AA\}$. Informacijski sadržaj 1D Carnapove entropije (5.15) zasnovan abecednim znakovima dan je u tablici 5.2. Sadržaj informacije nije jedinstven jer se za neka slova abecede npr. slova B, H i Q nalazi isti izraz za entropiju opisanu jediničnim skokovima.

Tablica 5.2. Informacijski sadržaj binarno kodirane skokovno opisane Carnapove entropije, prema razdiobi u tablici 5.2

Slijedne promjene	Razdioba signalnih obrazaca	1D-entropija popločenja	Znak
0 0 0	4L	$I=4L/L \log_2 L/L=0$	A
0 0 +	3L, (L+Δ)	$I=3(L+\Delta/2)/(L+\Delta) \log_2(A)^* + (\Delta/2)/(L+\Delta) \log_2(B)^*$	B=H=Q
0 0 -	(L-Δ), 3L	$I=3(L-\Delta/2)/L \log_2(A)^* + (\Delta/2)/L \log_2(B)^*$	C
0 + 0	2L, 2(L+Δ)	$I=2(L+\Delta/2)/(L+\Delta) \log_2(A)^* + 2(\Delta/2)/(L+\Delta) \log_2(B)^*$	D
0 - 0	2(L-Δ), 2L	$I=2(L-\Delta/2)/L \log_2(A)^* + 2(\Delta/2)/L \log_2(B)^*$	E=O=Z
0 + +	2L, L+Δ, L+2Δ	$I=2(L+\Delta/2)/(L+2\Delta) \log_2(A)^* + (\Delta/2)/(L+2\Delta) \log_2(B)^* + (\Delta/2)/(L+2\Delta) \log_2(C)^*$	F
0 - -	L-2Δ, L-Δ, 2L	$I=(L-(3/2)\Delta/2)/L \log_2(A)^* + \Delta/L \log_2(B)^* + 2(\Delta/2)/L \log_2(C)^*$	G
0 + -	3L, L+Δ	$I=3(L+\Delta/2)/(L+\Delta) \log_2(A)^* + (\Delta/2)/(L+\Delta) \log_2(B)^*$	H=B=Q
0 - +	L-Δ, 3L	$I=(L-\Delta/2)/L \log_2(A)^* + 3(\Delta/2)/L \log_2(B)^*$	I=S

+ 0 0	$L, 3(L+\Delta)$	$I=(L+\Delta/2)/(L+\Delta) \log_2(A)^* + 3(\Delta/2)/(L+\Delta) \log_2(B)^*$	J
- 0 0	$3(L-\Delta), L$	$I=3(L-\Delta/2)/L \log_2(A)^* + (\Delta/2)/L \log_2(B)^*$	K
+ 0 +	$L, 2(L+\Delta), L+2\Delta$	$I=(L+\Delta/2)/(L+2\Delta) \log_2(A)^* + 2(\Delta/2)/(L+2\Delta) \log_2(B)^* + (\Delta/2)/(L+2\Delta) \log_2(C)^*$	L
+ 0 -	$2L, 2(L+\Delta)$	$I=2(L+\Delta/2)/(L+\Delta) \log_2(A)^* + 2(\Delta/2)/(L+\Delta) \log_2(B)^*$	M=V
- 0 -	$L-2\Delta, 2(L-\Delta), L$	$I=(L-(3/2)\Delta/2)/L \log_2(A)^* + 2\Delta/L \log_2(B)^* + (\Delta/2)/L \log_2(C)^*$	N=Y
- 0 +	$2(L-\Delta), 2L$	$I=2(L-\Delta/2)/L \log_2(A)^* + 2(\Delta/2)/L \log_2(B)^*$	O=Z=E
+ + 0	$L, L+\Delta, 2(L+2\Delta)$	$I=(L+\Delta/2)/(L+2\Delta) \log_2(A)^* + (\Delta/2)/(L+2\Delta) \log_2(B)^* + 2(\Delta/2)/(L+2\Delta) \log_2(C)^*$	P
+ - 0	$3L, L+\Delta$	$I=3(L+\Delta/2)/(L+\Delta) \log_2(A)^* + (\Delta/2)/(L+\Delta) \log_2(B)^*$	Q=H=B
- - 0	$2(L-2\Delta), L-\Delta, L$	$I=2(L-(3/2)\Delta/2)/L \log_2(A)^* + \Delta/L \log_2(B)^* + (\Delta/2)/L \log_2(C)^*$	R
- + 0	$L-\Delta, 3L$	$I=(L-\Delta/2)/L \log_2(A)^* + 3(\Delta/2)/L \log_2(B)^*$	S=I
+ + +	$L, L+\Delta, L+2\Delta, L+3\Delta$	$I=(L+\Delta/2)/(L+3\Delta) \log_2(A)^* + 2(\Delta/2)/(L+3\Delta) \log_2(B)^* + (\Delta/2)/(L+3\Delta) \log_2(C)^*$	T
+ + -	$L, 2(L+\Delta), L+2\Delta$	$I=(L+\Delta/2)/(L+2\Delta) \log_2(A)^* + 2(\Delta/2)/(L+2\Delta) \log_2(B)^* + (\Delta/2)/(L+2\Delta) \log_2(C)^*$	U
+ - +	$2L, 2(L+\Delta)$	$I=2(L+\Delta/2)/(L+\Delta) \log_2(A)^* + 2(\Delta/2)/(L+\Delta) \log_2(B)^*$	V=M
+ - -	$L-\Delta, 2L, L+\Delta$	$I=(L-\Delta/2)/(L+\Delta) \log_2(A)^* + 2(\Delta/2)/(L+\Delta) \log_2(B)^* + (\Delta/2)/(L+\Delta) \log_2(C)^*$	W=AA
- - -	$L-3\Delta, L-2\Delta, L-\Delta, L$	$I=(L-(5/2)\Delta)/L \log_2(A)^* + 2\Delta/L \log_2(B)^* + (\Delta/2)/L \log_2(C)^*$	X
- - +	$L-2\Delta, 2(L-\Delta), L$	$I=(L-(3/2)\Delta/2)/L \log_2(A)^* + 2\Delta/L \log_2(B)^* + (\Delta/2)/L \log_2(C)^*$	Y=N
- + -	$2(L-\Delta), 2L$	$I=2(L-\Delta/2)/L \log_2(A)^* + 2(\Delta/2)/L \log_2(B)^*$	Z=O=E
- + +	$L-\Delta, 2L, L+\Delta$	$I=(L-\Delta/2)/(L+\Delta) \log_2(A)^* + 2(\Delta/2)/(L+\Delta) \log_2(B)^* + (\Delta/2)/(L+\Delta) \log_2(C)^*$	AA=W

()* Označava izraz koji slijedi logaritamsku funkciju, L je apsolutni iznos početnog mjerenja, Δ je jedinična promjena

Ekspanzija informacijskog sadržaja abecede se razmatra zbog prilagođenja unaprijednim promjenama između svakog od četiriju mjerenja čime se kvantificira vremenska dinamika sistema. Ove promjene mogu se prikazati slično kao u radu [126] s matricom razlika:

$$\begin{bmatrix} \Delta_{1,2}\Delta_{2,3}\Delta_{3,4} \\ \times \Delta_{1,3}\Delta_{2,4} \\ \times \times \Delta_{1,4} \end{bmatrix} \quad (5.17),$$

Gdje je $\Delta_{i,j}$ jedinična promjena između mjerenja i te mjerenja j , a oznaka \times stoji za irelevantan element matrice. Vektor ekspanzije promjena može se dobiti konzekutivnim zapisom kao: $(\Delta_{1,2}\Delta_{2,3}\Delta_{3,4}\Delta_{1,3}\Delta_{2,4}\Delta_{1,4})$. Taj vektor kodira sve moguće kvalitativne promjene među četiri uzastopna mjerenja i na promjenu jednog koraka dodaje informaciju promjene između dvaju koraka te promjene između tri koraka mjerenja. Informacijski sadržaj ekspandirane entropije svih 27 znakova prikazan je tablicom 5.3. Informacija je sada jedinstvena za svaki znak abecede.

Tablica 5.3. Informacijski sadržaj ternarno kodiranih znakova abecede nakon ekspanzije unaprijed

Znak	Vektorsko predstavljanje matrice ekspanzije	Razdioba signalnih obrazaca	1D-entropija popločenja
A	0 0 0 0 0 0	6L	0
B	0 0 + 0 + +	2L, 2(L+Δ), L+2Δ, L+3Δ	$2\{(L+\Delta/2)/(L+3\Delta)\}\log_2\{A\}^* + 3\{\Delta/(L+3\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+3\Delta)\}\log_2\{C\}$
C	0 0 - 0 - -	L-3Δ, L-2Δ, 2(L-Δ), 2L	$\{(L-(5/2)\Delta)/L\}\log_2\{A\} + 3\{\Delta/L\}\log_2\{B\} + 2\{(\Delta/2)/L\}\log_2\{C\}$
D	0 + 0 + + +	L, 2(L+Δ), L+2Δ, L+3Δ, L+4Δ	$\{(L+\Delta/2)/(L+4\Delta)\}\log_2\{A\} + 4\{\Delta/(L+4\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+4\Delta)\}\log_2\{C\}$
E	0 - 0 - - -	L-4Δ, L-3Δ, L-2Δ, 2(L-Δ), L	$\{(L-(7/2)\Delta)/L\}\log_2\{A\} + 4\{\Delta/L\}\log_2\{B\} + \{(\Delta/2)/L\}\log_2\{C\}$
F	0 + + + + +	L, L+Δ, L+2Δ, L+3Δ, L+4Δ, L+5Δ	$\{(L+\Delta/2)/(L+5\Delta)\}\log_2\{A\} + 4\{\Delta/(L+5\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+5\Delta)\}\log_2\{C\}$
G	0 - - - - -	L-5Δ, L-4Δ, L-3Δ, L-2Δ, L-Δ, L	$\{(L-(9/2)\Delta)/L\}\log_2\{A\} + 4\{\Delta/L\}\log_2\{B\} + \{(\Delta/2)/L\}\log_2\{C\}$
H	0 + - + 0 0	2L, 4(L+Δ)	$2\{(L+\Delta/2)/(L+\Delta)\}\log_2\{A\} + 4\{(\Delta/2)/(L+\Delta)\}\log_2\{B\}$

I	0 - - 0 0	$4(L-\Delta), 2L$	$4\{(L-\Delta/2)/L\}\log_2\{A\} + 2\{(\Delta/2)/L\}\log_2\{B\}$
J	+ 0 0 + 0 +	$3(L+\Delta), 2(L+2\Delta), L+3\Delta$	$3\{(L+\Delta/2)/(L+3\Delta)\}\log_2\{A\} + 2\{\Delta/(L+3\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+3\Delta)\}\log_2\{C\}$
K	- 0 0 - 0 -	$L-3\Delta, 2(L-2\Delta), 3(L-\Delta)$	$\{(L-(5/2)\Delta)/L\}\log_2\{A\} + 2\{\Delta/L\}\log_2\{B\} + 3\{(\Delta/2)/L\}\log_2\{C\}$
L	+ 0 + + + +	$2(L+\Delta), L+2\Delta, L+3\Delta, L+4\Delta, L+5\Delta$	$2\{(L+\Delta/2)/(L+5\Delta)\}\log_2\{A\} + 3\{\Delta/(L+5\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+5\Delta)\}\log_2\{C\}$
M	+ 0 - - - 0	$3L, 3(L+\Delta)$	$3\{(L+\Delta/2)/(L+\Delta)\}\log_2\{A\} + 3\{(\Delta/2)/(L+\Delta)\}\log_2\{B\}$
N	- 0 - - - -	$L-5\Delta, L-4\Delta, L-3\Delta, L-2\Delta, 2(L-\Delta)$	$\{(L-(9/2)\Delta)/L\}\log_2\{A\} + 3\{\Delta/L\}\log_2\{B\} + 2\{(\Delta/2)/L\}\log_2\{C\}$
O	- 0 + - + 0	$3(L-\Delta), 3L$	$3\{(L-\Delta/2)/L\}\log_2\{A\} + 3\{(\Delta/2)/L\}\log_2\{B\}$
P	+ + 0 + + +	$L+\Delta, 2(L+2\Delta), L+3\Delta, L+4\Delta, L+5\Delta$	$\{(L+\Delta/2)/(L+5\Delta)\}\log_2\{A\} + 4\{\Delta/(L+5\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+5\Delta)\}\log_2\{C\}$
Q	+ - 0 0 - 0	$2(L-\Delta), 3L, L+\Delta$	$2\{(L-\Delta/2)/(L+\Delta)\}\log_2\{A\} + 3\{(\Delta)/(L+\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+\Delta)\}\log_2\{C\}$
R	- - 0 - - -	$L-5\Delta, L-4\Delta, L-3\Delta, 2(L-2\Delta), L-\Delta$	$\{(L-(9/2)\Delta)/(L-\Delta)\}\log_2\{A\} + 4\{\Delta/(L-\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L-\Delta)\}\log_2\{C\}$
S	- + 0 0 + 0	$L-\Delta, 3L, 2(L+\Delta)$	$\{(L-\Delta/2)/(L+\Delta)\}\log_2\{A\} + 3\{(\Delta)/(L+\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+\Delta)\}\log_2\{C\}$
T	+ + + + + +	$L+\Delta, L+2\Delta, L+3\Delta, L+4\Delta, L+5\Delta, L+6\Delta$	$\{(L+3\Delta/2)/(L+6\Delta)\}\log_2\{A\} + 4\{\Delta/(L+6\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+6\Delta)\}\log_2\{C\}$
U	+ + - + 0 +	$2(L+\Delta), 3(L+2\Delta), L+3\Delta$	$2\{(L+3\Delta/2)/(L+3\Delta)\}\log_2\{A\} + 3\{\Delta/(L+3\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+3\Delta)\}\log_2\{C\}$
V	+ - + 0 0 +	$L, 4(L+\Delta), L+2\Delta$	$\{(L+\Delta/2)/(L+2\Delta)\}\log_2\{A\} + 4\{\Delta/(L+2\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+2\Delta)\}\log_2\{C\}$
W	+ - - 0 - -	$L-3\Delta, L-2\Delta, 2(L-\Delta), L, L+\Delta$	$\{(L-(5/2)\Delta)/(L+\Delta)\}\log_2\{A\} + 4\{\Delta/(L+\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+\Delta)\}\log_2\{C\}$
X	- - - - - -	$L-6\Delta, L-5\Delta, L-4\Delta, L-3\Delta, L-2\Delta, L-\Delta$	$\{(L-(11/2)\Delta)/(L-\Delta)\}\log_2\{A\} + 4\{\Delta/(L-\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L-\Delta)\}\log_2\{C\}$
Y	- - + - 0 -	$L-3\Delta, 3(L-2\Delta), 2(L-\Delta)$	$\{(L-(5/2)\Delta)/(L-\Delta)\}\log_2\{A\} + 3\{\Delta/(L-\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L-\Delta)\}\log_2\{C\}$
Z	- + - 0 0 -	$L-2\Delta, 4(L-\Delta), L$	$\{(L-(3/2)\Delta)/L\}\log_2\{A\} + 4\{\Delta/L\}\log_2\{B\} + \{(\Delta/2)/L\}\log_2\{C\}$
AA	- + + 0 + +	$L-\Delta, L, 2(L+\Delta), L+2\Delta, L+3\Delta$	$\{(L-\Delta/2)/(L+3\Delta)\}\log_2\{A\} + 4\{(\Delta)/(L+3\Delta)\}\log_2\{B\} + \{(\Delta/2)/(L+3\Delta)\}\log_2\{C\}$

Sljedeći korak jest da se ove jedinične promjene prenesu na stvarne kvantitativne promjene pojedinih mjerenja. Neka je $X = (x_1, x_2, x_3, x_4), x_i \in R$ četvorka slijednih kvantitativnih mjerenja na vremenskoj seriji procesnih podataka. Matrica razlika ove četvorke može se prikazati kao:

$$\begin{bmatrix} d_{1,2} d_{2,3} d_{3,4} \\ \times d_{1,3} d_{2,4} \\ \times \times d_{1,4} \end{bmatrix} \quad (5.18),$$

te pripadni vektor ekspanzije kao $(d_{1,2} d_{2,3} d_{3,4} d_{4,5} d_{5,6})$. Odatle se šestorka definira kao:

$Y = (y_1, y_2, y_3, y_4, y_5, y_6)$, gdje je:

$$y_1 = x_1 + d_{1,2} = x_2, y_2 = x_2 + d_{2,3} = x_3, y_3 = x_3 + d_{3,4} = x_4, y_4 = y_3 + d_{1,3}, y_5 = y_4 + d_{2,4}, y_6 = y_5 + d_{1,4} \quad (5.19)$$

Budući da nema garancije da su vrijednosti Y sada dane u rastućem nizu nužnim za izračun entropije prema (5.15) njihove se vrijednosti moraju sortirati prije proračuna entropije. Njihovo sortiranje ne utječe na šestorku zbog toga što su sve promjene već kodirane. Neka je $Z(z_1, z_2, z_3, z_4, z_5, z_6)$ šestorka sortiranih veličina Y . Abecedna entropija može se na taj način izračunati za bilo koja četiri uzastopna mjerenja kao:

$$AlphEn = - \left(\frac{z_1+z_2}{2z_6} \log_2 \frac{z_1+z_2}{2z_6} + \sum_{i=2}^5 \frac{z_{i+1}-z_{i-1}}{2z_6} \log_2 \frac{z_{i+1}-z_{i-1}}{2z_6} + \frac{z_6-z_5}{2z_6} \log_2 \frac{z_6-z_5}{2z_6} \right) (bit/opseg \text{ mjerenja}) \quad (5.20)$$

Ukoliko postoje neka jednaka mjerenja unutar šestorke tada se logaritam u (5.20) ne može izračunati. U tim slučajima neki se logaritmi uzimaju više puta u izračun dok se oni koji sadrže jednaka mjerenja izostavljaju. Na primjer šestorka $Z(2,2,5,5,5,8)$ bi se izračunala kao:

$$AlphEnZ = - \left(\frac{2*2+5}{2*8} \log_2 \frac{2+5}{2*8} + \frac{3*8-2}{2*8} \log_2 \frac{8-2}{2*8} + \frac{8-5}{2*8} \log_2 \frac{8-5}{2*8} \right) (bit/opseg \text{ mjerenja})$$

5.3.3.2. Primjena teselacijske entropije na kontrolu kvalitete obročnog industrijskog procesa

Teselacijska entropija (entropija popločenja) proširenog mjernog signala može se primijeniti na kontrolu kvalitete industrijskog obročnog procesa uporabom sljedećeg postupka:

1. Svi se mjerni signali kontrole kvalitete uključujući i podatke izlazne kontrole kvalitete proizvoda normiraju u područje amplituda $[1, 2]$ kako bi se mogli usporediti signali različite amplitude i raspona mjernih vrijednosti.
2. Sve se signale kodira u abecedne znakove prema tablici 5.2. Duljina abecednog koda je kraća od signalne duljine za tri znaka jer se za kodiranje svakog znaka upotrebljavaju četiri slijedne mjerne veličine signala, sve prema tablici 5.2.
3. Proširena teselacijska entropija računa se za sve normirane mjerne signale uključujući i podatke izlazne kontrole kvalitete proizvoda i za svaki kodirani znak prema izrazu (5.20).
4. Konstruira se graf nazvan impaktogram koji pokazuje suodnos između kodnih znakova (tablica 5.2) pojedinih mjernih mjesta signala kvalitete i varijable izlazne kontrole kvalitete za svaki mjerni trenutak praćenja procesnih signala. Za svako mjerenje i za svaki signal impaktogram sadrži jednu od tri moguće vrijednosti: 0, 1, ili 2. Vrijednost je jednaka 0 za mjerni trenutak gdje se kodni znak izlazne kvalitete proizvoda i mjerni signal nekog mjerenja ne poklapaju. Vrijednost je jednaka 1 ako se navedeni kodni znakovi poklapaju a razlika izračunate proširene teselacijske entropije nije najmanja uspoređujući sve ostale izračunate entropije svih signala s istim kodnim znakom za taj trenutak mjerenja. Vrijednost je jednaka 2 ako se navedeni kodni znakovi poklapaju, a razlika izračunate proširene teselacijske entropije je najmanja uspoređujući sve ostale izračunate entropije svih signala s istim kodnim znakom za taj trenutak mjerenja. U posebnom slučaju kada se kodni znakovi signala izlazne kvalitete i iznosi pripadne entropija poklapaju za dva ili više procesna mjerna signala tada će svi poprimiti vrijednost 2 za taj trenutak mjerenja.

S impaktograma se tumače samo oni mjerni trenutci koji su značajni za potrebe službe kontrole kvalitete. Budući da proširena teselacijska entropija upotrebljava tri mjerenja koji

prethode pojavi značajnoj za istraživanje od strane službe kontrole kvalitete, svi se oni uključuju u navedeno područje tumačenja od strane službe kontrole kvalitete. Daljnje istraživanje poduzima se samo za one procesne signale koji su relevantni to jest koji imaju iskazanu vrijednost 1 ili 2 u danom trenutku i u periodu koji prekriva navedeno područje interesa službe kontrole kvalitete izlaznog proizvoda.

5. Impaktogram se upotrebljava za određivanje mjesta pojave uzroka od značaja za kontrolu kvalitete. U automatiziranoj proizvodnji najčešće postoji jedan osnovni razlog promjene kvalitete izlaznog proizvoda. Iznimno, gotovo se istodobno mogu dogoditi dva uzroka jedne pojave promjene kvalitete izlaznog proizvoda. Uzroci se mogu odraziti i u mjernim iznosima drugih procesnih signala koji mjere značajke izlaznog proizvoda. Proces tumačenja može se izreći jasno zbog po definiciji nedvosmislene prirode proširene teselacijske entropije [Jović, 2011] na sljedeći način:

5.1 Prvo se izlistaju relevantni signali za relevantne mjerne trenutke.

5.2 Zatim se započinje od prvog relevantnog mjernog trenutka. Iznosi entropija svih relevantnih signala, to jest onih kojima su iznosi 1 ili 2 u prvom relevantnom trenutku uspoređuju se s entropijom signala izlazne kontrole kvalitete. Signali koji imaju iznos 2 su najvjerojatniji uzročnici pojave promjene izlazne kvalitete. Ako postoje dva ili više takva relevantna signala razmatra se samo onaj s iznosom entropije najbliži iznosu entropije izlaznog signala kvalitete, a ostali se zanemaruju. Ako postoje signali s kodom 1, a po iznosu entropije bliski izlaznom signalu kvalitete oni se ne zanemaruju kao mogući uzroci promjene kvalitete procesa. Ako izuzetno postoje više od dva moguća uzroka, oni su obično malo vremenski pomaknuti. Tada se oni signali s većim iznosom razlike entropije prema entropiji izlaznog signala kvalitete odbacuju. Uzrok promjene kvalitete može se obično otkriti u prvom relevantnom trenutku, no katkada se može pronaći i u sljedećem relevantnom trenutku koji isto tako prethodi značajnoj promjeni varijable izlazne kvalitete proizvoda.

5.3 Konačno se svi relevantni signali nastavljaju izlistavati za svaki trenutak poslije trenutka u kojem je otkriven uzrok, s ciljem da se pronađe na koje su signale djelovali poremećaji u procesu proizvodnje. Entropijski iznosi svih relevantnih signala uspoređuju se s entropijom signala kvalitete izlaznog proizvoda. Signali s vrijednosti 2 su najvjerojatniji indikatori učinaka neispravnosti. Ako postoje signali s vrijednostima 1 čiji su iznosi entropije također blizu iznosu entropije signala izlazne kvalitete oni se također ne odbacuju kao dodatni utjecajni čimbenici neispravnosti.

5.4 Ovim postupkom otkrivaju se uzroci i posljedice kvarova u procesu proizvodnje. Zadatak kontrole kvalitete je djelovanje na podešavanje radnih parametara strojeva da bi se kvarovi smanjili ili potpuno otklonili.

5.3.4. Detaljan opis primjera određivanja potencijalnog uzroka kvara na prešama Magnum

5.3.4.1. Opis skupa mjernih podataka kontrole kvalitete

Razmatrani skup mjernih podataka sastoji se od 204 mjerenja dobivenih sa pet preša u kolovozu i rujnu 2008. godine u tvornici „KIO Keramika“ d.o.o. u Orahovici. Podaci su dobiveni po smjenama, dakle postojali su od jedne do tri smjenska izvještaja po radnom danu tvornice, ovisno o broju smjena određenog dana. Svi proizvodi jedne smjene bili su u istoj smjeni kontrolirani u završnoj kontroli.

Mjerni signali su: signal vlažnosti pločice (s10), signali temperature s preše (s11-s14), signali debljine okvira na preši (s16-s20), signali debljine preko okvira preše (s21-s25), signali skošenosti okvira preše (s26-s30), signali skošenosti preko okvira preše (s31-s35), signali čvrstoće pločice (s36-s40) i signali temperature peći (s44-s51). Svi su mjerni signali bili brojčani.


Cilj jest odrediti model ponašanja varijable izlazne kvalitete keramičkih pločica, označenog sa QC, koji je dan kao postotak otpada (škarta) po smjeni. Model treba dati odgovor koji od

navedenih signala s preše ili peći utječu na kvalitetu konačnog proizvoda te u kojem vremenskom periodu, kako bi se moglo prevenirati stvaranje škarta.



Svih pet preša nije radilo cijelo vrijeme. Najviše su radile preše #9 i #10 tipa Magnum i to sa 60 odnosno 58 smjenskih mjerenja. Za vrijeme rada tih preša dogodio se veći broj pojava s nezadovoljavajućom kvalitetom cjelokupnog procesa koji je rezultirao pojavom otpada od 6 i više postotaka proizvedenih keramičkih pločica. Histogram vrijednosti signala QC za spomenute dvije preše dan je na slici 5.3. Norme kvalitete kao što su ISO 3951-1:2005 i ISO 8423:2008 traže da je „proizvodnja stabilna (pod statističkim nadzorom) i da je karakteristika kvalitete x razdijeljena prema normalnoj razdiobi ili bliskoj aproksimaciji normalnoj razdiobi“. Slučaj koji se ne slaže s ovim zahtjevom prikazan je na slici 5.3 za signal QC u tvornici „KIO Keramika“, što je uobičajen slučaj za većinu tvornica s relativno kratkim serijama proizvoda. Razdioba za preše #9 i #10 je u maloj mjeri slična normalnoj razdiobi. Također, razdioba sadrži neke ekstremne vrijednosti, što znači da postoji nestabilnost u sustavu koja treba biti uklonjena.

Pearsonov koeficijent korelacije svakog pojedinog signala sa signalom QC za ove dvije preše dan je na slici 5.4. Sa slike 5.4 razvidno je da su neki signali jače povezani sa signalom QC od drugih signala. Međutim koeficijent korelacije nije gotovo nikada prelazio iznos $r = 0.5$ što teorijski znači da nijedan signal nije utjecao više od $r^2 = 0.25 = 25\%$ na varijancu QC signala. Isto tako vidljivo je sa slike 5.4 da su neki signali međusobno jako korelirani, poput signala s44-s47 i to na svakoj preši.

Korelacijska analiza može odrediti koji signal ili grupe signala su korelirane s QC. No za određivanje trenutaka kada su signali povezani s QC potrebno je provesti analizu putem proširene teselacijske entropije.



Slika 5.3. Histogram signala QC za prešu #9 (lijevo) i prešu #10 (desno) u tvornici „KIO Keramika“, Orahovica.



Slika 5.4. Pearsonov koeficijent korelacije izračunat između svakog procesnog signala i signala QC za preše #9 i #10 u tvornici „KIO Keramika“, Orahovica.

5.3.4.2. Impaktogram za preše #9 i #10 Magnum

Impaktogrami za preše #9 i #10 dani su na slici 5.5. odnosno slici 5.6. Elementi impaktograma s mjernim vrijednostima 0 kodirani su bijelo, s vrijednostima 1 kodirani su sivo, a s vrijednostima 2 kodirani su tamno sivo. Relevantne mjerne pojave su također označene i razdvojene od irelevantnih mjernih pojava dvjema okomitim linijama. Dani su sljedeći primjeri tumačenja pojava na impaktogramu, po jedan za svaku prešu, za detalje vidjeti dodatak D, a podaci škarta dani su u tablici 5.5.:

1) Mjereni događaj broj 30 na preši #9 je kritičan jer pokazuje 7.41% škarta. Sljedeći signali i trenutki su relevantni za tu pojavu: $s33(t=28) = „1“$, $s50(t=28) = „2“$, $s33(t=29) = „2“$, $s50(t=30) = „1“$, $s39(t=30) = „2“$.

Entropije signala u intervalu $t=29$ do $t=33$ iznose $I(s33) = 1.792$, $I(s50) = 1.545$ i $I(QC) = 1.569$. Vidimo da je u trenutku 28 entropija signala $s33$ po iznosu dalja od entropije QC signala od entropije signala $s50$, pa signal $s33$ vjerojatno nije uzrok pada kvalitete. S druge strane entropija u trenutku 29 za signale iznosi $I(s33) = 1.792$, $I(s50) = 2.044$ i $I(QC) = 1.625$. Vidimo da je entropija signala $s33$ bliža entropiji QC u intervalu 29 nego u intervalu 28. To znači da se uzrok započeo pokazivati u značajki preše tj. u skošenosti preko okvira preše.

Entropija u $t=30$ iznosila je $I(s30) = 2.584$, $I(s39) = 1.500$ i $I(QC) = 1.225$. Blisko preklapanje signala $s39$ i signala QC sugerira da se uzrok također pokazao u povećanju tvrdoće pločica što je dovelo do lakšeg pucanja pločica i više škarta.

Ovo tumačenje potvrđuje da anomalija uvjeta u peći vodi do povećanja skošenosti preko okvira preše i povećanoj tvrdoći pločica što oboje vodi do povećanja škarta.

2) Mjerni trenutki od 28-30 na preši #10 su kritični jer je $QC=6.17\%$ u sva tri trenutka opažaja. U području od 25-30 i nakon odbacivanja redundantnih visoko koreliranih signala


ostaju zanimljivi za daljnju analizu sljedeći signali: $s_{10}(t=26) = „2“$, $s_{17}(t=27) = „1“$, $s_{19}(t=27) = „1“$, $s_{29}(t=27) = „2“$, $s_{38}(t=27) = „1“$, $s_{49}(t=27) = „1“$.

Entropija u $t=26$ iznosi: $I(s_{10}) = 1.180$, $I(QC) = 0.954$. Signal s_{10} povećane vlage pločica je vjerojatan uzrok kritične pojave.


Entropija u $t=27$: $I(s_{17}) = 1.886$, $I(s_{19}) = 1.389$, $I(s_{29}) = 1.792$, $I(s_{39}) = 1.442$, $I(s_{49}) = 1.056$, $I(QC) = 1.792$.

Entropija signala s_{29} je najbliža entropiji QC u $t=27$ što naznačava da se greška odražava u povećanoj skošenosti među okvirima preše #10. Ova greška također uključuje i drugi najbliži razlog lakšeg pucanja pločica, signal s_{17} (povećana debljina preko okvira preše).

Druge kritične pojave na prešama #9 i #10 su također lako objašnjive upotrebom navedenog postupka. Otkriva se da su uzroci koji vode do većine najizrazitijih pojava škarta: 1) neispravno rukovanje pećima koje se odražava u povećanju signala s_{50} iznad uobičajenih iznosa i 2) povećanje vlažnosti pločica koje odražava signal s_{10} . Uobičajena posljedica bila je 1) povećanje tvrdoće koje se odrazilo u signalima s_{36} - s_{40} i 2) oscilacije signala okvira preše zbog povećanja varijacije tih signala. Primjena navedenih postupaka objašnjava sve pojave škarta iznad graničnih 6%.



Slika 5.5. Impaktogram za prešu #9 u tvornici „KIO Keramika“, Orahovica



Slika 5.6. Impaktogram za prešu #10 u tvornici „KIO Keramika“, Orahovica

5.3.5. Detaljan opis primjera određivanja potencijalnog uzroka na dvokanalnoj peći

5.3.5.1. Dvokanalna peć

Dvokanalna peć firme Siti koja je radila u poduzeću KIO Keramika Orahovica u promatranom razdoblju analize 8. i 9. mjeseca 2009. godine, ima ukupnu dužinu od 77 metara od čega je 67 metara područje predgrijavanja, pečenja i hlađenja. Podaci o postavnim veličinama uzdužnom rasporedu i kodu senzora, stvarnim temperaturama i greškama te komunikaciji s operaterom za kanal 1 dvokanalne peći dani su u tablici 5.4. za proizvodnju pločica SKY YEL dimenzija 250x200 mm. Signali s44 i s45 prvog kanala prikupljaju se s pozicije 1092/1091 dakle na 39,5 metara a signali s46 i s47 s pozicije 1102/1101 dakle na 44 metra od početka peći u prvom kanalu. Njima korespondentni signali s48 i s49 se prikupljaju na 39,5 metru u drugom kanalu dvokanalne peći, te s50 i s51 na 44. metru dvokanalne peći u kanalu 2. Budući da su to zone najviše temperature peći, koje drastično utječu na proces pečenja i na kvalitetu keramičkih pločica to se na tim mjestima toleriraju odstupanja u pravilu od 5°C, kao što je na navedenom primjeru iz tablice 5.4, na pozicijama rednog broja 9. i 10. iz tablice 5.4, za senzore signalnog koda s45 i s47.

Tablica 5.4. Uzdužni raspored temperaturnih senzora, temperatura, postavnih iznosa i izmjerenih temperatura za keramičke pločice SKY YEL dimenzija 250x200 mm; pripadne greške i stanje dojave; sve za kanal 1 dvokanalne peći Siti.

Kanal 1 redni broj	Uzdužna pozicija [m]	Mjerni senzor kod*	Postavna temperatura °C	Stvarna temperatura °C	Apsolutna greška °C	Status dojave kod**
1.	6	1012	370	386	16	com
2.	10,5	1022	550	548	2	com
3.	14,5	1032	740	705	35	com
4.	18,5	1042	790	743	47	com
5.	23	1052	870	797	73	k/al
6.	27,5	1062	900	833	67	k/al
7.	31,5	1072	950	908	42	k/al
8.	36	1082	1010	989	21	com

9.	39,5	s45/1092	1109	1108	1	com
10.	44	s47/1102	1125	1124	1	com
11.	47	1112	1085	1080	5	com
12.	51,5	1122	640	640	0	com
13.	55,5	1132	540	547	7	com
14.	59,5	1142	460	481	21	com
15.	66	1152	250	310	60	com

* kod mjernog senzora s45 i s47 je posebno označen

** com - redovita dojava, k/al - dojava alarmnog stanja

5.3.5.2. Podaci dvokanalne peći

Izvod iz podataka smjenskih izvještaja mjernih signala dvokanalne peći za sirove pločice s preše iz perioda smjena u 8. i 9. mjesecu 2009. godine dan je u tablici 5.5.


Tablica 5.5 Dio podataka QC signala i signala s dvokanalne peći s preše sirovih pločica u razdoblju 8. i 9. mjeseca 2009. godine; svi signali dvokanalne peći s44-s51 su iz područja zone maksimalne temperature i dani su u stupnjevima celzusa; QA signala je dan u postotku škarta završne kontrole

Škart ukupno [%]	signal 48	signal 49	signal 50	signal 51	signal 44	signal 45	signal 46	signal 47
4,29	1121	1128	1121	1121	1160	1135	1160	1135
2,62	1123	1128	1123	1123	1160	1143	1160	1143
2,62	1123	1128	1123	1123	1160	1143	1160	1143
2,62	1123	1128	1123	1123	1160	1143	1160	1143
1,62	1123	1128	1123	1123	1153	1142	1153	1142
1,62	1123	1128	1123	1123	1153	1142	1153	1142
2,72	1126	1126	1126	1126	1153	1142	1153	1142
2,72	1126	1126	1126	1126	1153	1142	1153	1142
2,72	1126	1126	1126	1126	1153	1142	1153	1142
3,79	1120	1122	1120	1120	1151	1138	1151	1138
3,79	1120	1122	1120	1120	1151	1138	1151	1138

3,38	1118	1125	1118	1118	1151	1138	1151	1138
3,38	1118	1125	1118	1118	1151	1138	1151	1138
2,73	1116	1123	1116	1116	1151	1138	1151	1138
2,73	1116	1123	1116	1116	1151	1138	1151	1138
3,63	1116	1123	1116	1116	1151	1137	1151	1137
3,63	1116	1123	1116	1116	1151	1137	1151	1137
5,89	1116	1123	1116	1116	1151	1137	1151	1137
2,01	1123	1130	1123	1123	1154	1136	1154	1136
1,69	1128	1133	1128	1128	1162	1144	1162	1144
1,69	1128	1133	1128	1128	1162	1144	1162	1144
1,69	1128	1133	1128	1128	1162	1144	1162	1144
2,58	1130	1130	1130	1130	1160	1145	1160	1145
0,71	1132	1132	1132	1132	1165	1145	1165	1145
3,95	1132	1132	1132	1132	1162	1148	1162	1148
3,95	1132	1132	1132	1132	1162	1148	1162	1148
1,28	1130	1136	1130	1130	1162	1148	1162	1148
3,23	1129	1135	1120	1135	1162	1148	1162	1148
3,23	1129	1135	1120	1135	1162	1148	1162	1148
7,41	1129	1135	1129	1135	1162	1148	1162	1148
4,12	1118	1132	1118	1132	1165	1150	1165	1150
4,12	1118	1132	1118	1132	1165	1150	1165	1150
6,03	1118	1132	1118	1132	1165	1150	1165	1150
2,5	1118	1132	1118	1132	1160	1145	1160	1145
0,88	1120	1130	1120	1130	1160	1145	1160	1145
5,57	1120	1130	1120	1130	1160	1145	1160	1145
5,57	1120	1130	1120	1130	1160	1145	1160	1145
3,13	1120	1130	1120	1130	1160	1145	1160	1145
6,17	1118	1132	1118	1132	1162	1147	1162	1147
6,17	1118	1132	1118	1132	1162	1147	1162	1147
6,17	1118	1132	1118	1132	1162	1147	1162	1147
2,92	1118	1132	1118	1132	1162	1147	1162	1147
2,92	1118	1132	1118	1132	1162	1147	1162	1147
2,65	1118	1132	1118	1132	1162	1147	1162	1147
2,65	1118	1132	1118	1132	1162	1147	1162	1147
2,3	1118	1132	1118	1132	1162	1147	1162	1147
2,3	1118	1132	1118	1132	1162	1147	1162	1147
1,69	1122	1132	1122	1132	1167	1147	1166	1145
3,54	1122	1132	1122	1132	1167	1147	1166	1145

5.3.5.3. Izrada impaktograma

Prema referenciji [111], izračunati su kodni znakovi prema tablici 5.3 i entropije temperatura iz podataka u tablici 5.5 te uspoređene s kodnim znakovima i entropijom signala izlazne kvalitete. Na temelju sličnosti kodnih znakova i entropija izrađeni su impaktogrami za rad tunelskih peći sa smjenskim šaržama s preša 10,9,8 i 5 s prikazom prvih 18 smjenskih mjerenja impaktograma za rad sa sirovim pločicama iz preše 10, slika 5.7. Bijela polja su predviđena za događaje s različitim kodnim znakovima signala 44-51 prema kodnom znaku QC, plava za iste kodne znakove a crvena za događaje s istim kodnim znakovima i najvećim sličnostima izračunate kodne entropije.



Slika 5.7. Impaktogram za signale dvokanalne peći pri radu s pločicama iz preše broj 10 - prvih 18 smjena u 8. mjesecu 2009 godine: bijela polja su različiti kodni znakovi prema znaku QC signala, a plava i crvena za iste kodne znakove mjernih signala i signala QC. Crvena polja označavaju gotovo identične iznose teselacijskih entropija temperaturnih i QC signala

Pripadni izračuni jednodimenzijske teselacijske entropije dani su u tablici 5.6.

Tablica 5.6. Izračuni entropija za signale s dvokanalne peći za šarže s preše broj 10 – posebno su u redu 15 i 16 označena podudaranja entropijskih vrijednosti QC i s50 signala

	QC	s44	s45	s46	s47	s48	s49	s50	s51
1.	0,731	0	0,731	0	0,731	0	0	0	0
2.	1,377	0	0,72	0	0,72	0	0	0	0
3.	1,755	0	0	0	0	0	0	0	0
4.	1,542	0,988	0,797	0,988	0,797	2,063	2,125	2,063	1,924
5.	1,914	1,77	1,8	1,77	1,8	2,342	2,338	2,342	2,238
6.	1,762	0,632	0,853	0,632	0,853	0,593	0,475	0,593	0,56
7.	0,698	1,429	1,838	1,429	1,838	1,549	1,296	1,549	1,431
8.	1,28	0,718	0,61	0,718	0,61	0,988	1,625	0,988	0,897
9.	1,423	0,808	0,268	0,808	0,268	1,446	1,213	1,446	1,34
10.	1,725	0,771	1,269	0,771	1,269	0,385	0,772	0,385	0,354
11.	1,006	0,182	0,506	0,182	0,506	0,861	1,056	0,861	0,784
12.	0,401	0,873	1,065	0,873	1,065	1,354	1,354	2,794	1,062
13.	1,068	0	0	0	0	1,261	0,584	2,419	0,461
14.	1,096	0	0	0	0	1,326	1,241	3,126	0,966
15.	2,08	0	0	0	0	0	0	2,076	0
16.	0,878	0	0	0	0	0	0	0,876	0
17.	1,017	0,86	0,881	0,86	0,881	2,804	1,546	1,678	1,168
18.	2,109	0,376	0,385	0,376	0,385	2,425	1,431	2,425	1,093

5.3.5.4. Rezultati detaljnog istraživanja škarta impaktogramima po prešama uporabom signala s dvokanalne peći

U skladu s postupkom predloženim u [Jović, 2013] ovdje su dani rezultati interpretacije impaktograma za signale s tunelskih peći, vidjeti tablice 5.5. i 5.6 te sliku 5.7., te Dodatak D3.

Preša 5: trenutak 3 bio je nepovoljan sa škartom od 6.17%, no nijedan signal peći nije u području utjecaja. Zaključak: Na temelju signala peći nakon preše 5 ne može se ustanoviti što je pošlo po krivu u trenutku 3.

Preša 6: nema nepovoljnih trenutaka, jer su svi QC signali manji od 6.00.

Preša 8: trenutak 2 bio je nepovoljan (škart je 6.08%), no trenutak 2 nema nijedan signal peći u području utjecaja.

Zaključak: Na temelju signala peći nakon preše 8 ne može se ustanoviti što je pošlo po krivu u trenutku 2.

Preša 9:

1. Trenutak 30 bio je nepovoljan (škart je 7.41%), a trenutak 30 ima u području utjecaja: s50 crveno i s50 plavo. Entropija od $H(s50)=1.545$ u trenutku 28, a entropija signala kontrole kvalitete $H(QC)=1.569$ u trenutku 28 (2.044 vs 1.625 u trenutku 29).

Zaključak: signal s50 u trenucima 28 i 29 moguć je uzrok problema.

2. Trenutci 39-41 bili su nepovoljni (škart je 6.17%). Trenutci 39-41 imaju u području utjecaja: s44-s47 plavo, s49 i s51 plavo. Entropija signala koji se pojavljuju u trenutku 38 je: $H(s44)= 0.917$, $H(s45)= 0.958$, $H(s46)= 0.917$, $H(s47)= 0.958$, $H(s49)= 1.03$, $H(s51)= 0.798$.

Entropija od QC u trenutku 38 iznosi $H(QC)=1.792$ a signal s49 ima relativno slabo entropijsko poklapanje s QC ali najjače od ostalih signala. Moguće je da se problem ocrta na više mjesta u peći zbog drugih uzroka, a najveći utjecaj ima signal s pozicije peći s49.

Povećani škart u ostalim trenucima nije utjecan od strane nijednog mjesta u peći.

Preša 10:

1. Trenutci 18-19 bili su nepovoljni (škart je 7.41%) a imaju u području utjecaja: s48 plavo, s49 plavo, s50 crveno i plavo, s51 plavo. Entropija signala koji se pojavljuju u trenutku 15 je $H(s50)= 2.076$, Entropija QC u trenutku 15 iznosi $H(QC)= 2.080$. Signal s50 je vjerojatno mjesto kvara od strane peći jer ima vrlo blisku entropiju. Entropija signala koji se pojavljuju u trenutku 16 je $H(s50)= 0.876$ a entropija $H(QC)=0.878$

Signal s50 nadalje upućuje na mjesto uzroka kvara. Entropija signala koji se pojavljuju u trenutku 17 je:

$H(s50) = 1.678$, entropija $H(QC) = 1.017$. Utjecaj mjesta s50 na kvar se smanjio ali i dalje postoji.

Entropije signala koji se pojavljuju u trenutku 18 su: $H(s48) = 2.425$, $H(s49) = 1.431$, $H(s50) = 2.425$ i $H(s51) = 1.093$ te $H(QC) = 2.109$. Sa strane peći, mjesto kvara je moguće i dalje na peći kod pozicije s50 ali i na poziciji s48. Ostale dvije pozicije mogućeg kvara su entropijski predaleko.

U trenutku 19 kvar se više ne očituje na pećima.

2. Trenutak 22 bio je nepovoljan (škart je 6.03%), no u trenutku 22 nema nijednog signala peći u području kodnog utjecaja.

3. Trenutci 28-30 bili su nepovoljni (škart je 6.17%). Trenutci 28-30 imaju u području utjecaja: s44-s47 plavo, s49 i s51 plavo i to sve u trenutku 27. Entropije signala koji se pojavljuju u trenutku 27 su: $H(s44) = 0.613$, $H(s45) = 0.844$, $H(s46) = 0.613$, $H(s47) = 0.844$, $H(s49) = 1.056$ i $H(s51) = 0.784$ te $H(QC) = 1.792$.

Iako se utjecaj kvara možda očituje u gotovo cijeloj zoni maksimalne temperature obaju kanala peći, signali peći ne upućuju na to da su one uzrok kvara jer su entropije predaleke od entropije signala kvalitete.

6. ORGANIZACIJA I PROVEDBA DOBIVENIH REZULTATA NA POBOLJŠANJE EKONOMIČNOSTI PROIZVODNJE

6.1. Postojeće informacijske mjere i informacijski obrasci: opća konvergencija modela i stvarnog stanja proizvodnje

Informacija, obilježena ekvivalentnim smanjenjem neodređenosti pojava u određenom skupu objekata ili procesa, posjeduje različite mjere. Postojeći pristupi uglavnom mjere informaciju prema razdiobama vjerojatnosti na skupu objekata, a prema teoriji vjerojatnosti, pri čemu se objekt promatra kao generator tih vjerojatnosti. Postoji osnovni nesklad između teorije vjerojatnosti kao mjere informacije i pojava u stvarnom svijetu – dakle u objektima. Taj nesklad je najbolje opisan u Bayesovu stavku i primijenjen u Bayesovu teoremu [47], gdje se postulira da bilo koja pojava ma kako nevjerovatna ima vjerojatnost veću od ničice. Ovaj Bayesov stav poništava osnovni aksiom teorije vjerojatnosti o vjerojatnosti neke pojave jednake ničici [133]. Isto tako je vjerojatnost aproksimacija stanja prirode gdje se pojave određuju učestalošću događanja u nekom konačnom vremenu. Usprkos ovim očitim razlikama u tretmanu pojma vjerojatnosti Shannonova formula za izračun entropije označava logiku objekta ponašanja kao općeniti opis složenosti nekog objekta.

Cjelovita mjera informacijske makrodinamike objekta je integralna mjera informacijske blizine objekta svojem informacijskom modelu te također služi kao evaluator relativne složenosti u smislu definicije anticipativnih objekata po Robertu Rosenu [56],[58] i njegovog odnosa prema vlastitom modelu.

Kako je pokazao Vladimir Lerner početni problem minimiziranja objektove funkcionala neodređenosti, koji se mjeri razlikom modelskih i objektove procesa, svodi se na minimizaciju entropijskog funkcionala definiranog modelskim makroprocesom [35],[37].U stvarnosti međutim minimumi funkcionala modela i procesa ne koincidiraju, zbog nužno potrebnih uvedenih modelskih pojednostavljenja. Zbog neizbježne neodređenosti objekt i model nikada neće precizno korespondirati. Algoritmi informacijske makrodinamike ne opisuju ekzaktno promatrani složeni objekt već više pokušavaju dokučiti nepostojeću informaciju promatranog

objekta, koja se onda koristi za slijedne aproksimacije trenutno izgrađenih modela stvarnog objekta. Ovi se algoritmi razvijaju uz ograničenja koja dozvoljavaju stabilnost, robusnost, samoorganizacija, prilagodba i popravljavanje pogrešaka u sustavu, budući da se odvijaju unutar ograničenih razina i ograničenja unutarnjih kontrolnih akcija u sustavu.

Model koji se može samopopravljati i samopoboljšavati približava informacijsku makrokinamiku kao egzaktnu znanost modelima procesa poput onih koje Rosen pripisuje živim bićima, [52], [56], [57]. Stoga su modeli informacijske makrokinamike ujedno i modeli evolucijskih sustava [37], [57]. Međudjelovanjem s okolišem informacijski makromodel se ponaša poput živog organizma stvarajući i konzumirajući negentropiju ili entropiju [57].

Odatle slijedi da stvaranje modela, uz pomoć principa varijacije, nastaje kao dio postojanja objekta u procesu njegova preživljavanja i njegove evolucije. Poput koda dvostruke helikoide u živih bića mora se stvarati analogna struktura koja nužno objedinjuje materijalnu i nematerijalnu supstanciju postojanja. Osnovna kodna informacija mora dati takvu mogućnost ugradnje u sustav koji opstaje.

Osmatrač u takvom sustavu može biti dio tog sustava ili postojati izvan njega no da bi dobio uvid u regularnost ponašanja sustava osmatrač mora međudjelovati u njemu kao njegov dio. Osmatrač tada gradi model kao rezultat svojih promatranja, model koji predstavlja promišljanje o sustavu a uključuje djelovanje osmatrača na sustav. Takav interaktivni model osmatranja sastoji se od slijednih uzročno – posljedičnih koraka iniciranih od osmatračevih kontrola koje slijede iz potreba trenutnih modelovih potreba za prikupljanjem maksimuma informacije za vrijeme modelove otvorenosti za prijem informacije. Postoji mogućnost da neki ili više djelomičnih osmatrača izgrađuju svoje djelomične modele i prikupljaju njima specifično prilagođenu informaciju. Tada svaki od tih osmatrača ima svoj izgrađeni eksplicitni model koji se razlikuje od modela cijelog sustava.

Odnos između osmatračevog modela i sustava možemo opisati kao proces kodiranja i dekodiranja informacije bez postojanja apriornog rječnika znanja. Tvorba tog rječnika znanja je

kreativni čin koji uključuje semantiku dekodiranja uz poznavanje prilježće kodne sintakse. Taj je proces složen tipa Rosenove mjere složenosti [56]. Odatle je model informacijske makrokinamike sustavski formalizam koji maksimalno aproksimira taj model stvarnog svijeta. U procesu izvlačenja maksimuma vanjske informacije s informacijske mikrorazine i njezine slučajnosti model koji se dobiva bira i povezuje svaki od tih sekundarnih izvora informacije po principu lokalnih minimuma. Odabrani informacijski detalj treba također zadovoljiti modelske unutrašnje invarijante i biti u koherenciji s općim pravilnostima modela. Ovime se doprinosi poboljšavanju modela u borbi za „bolji maksimum“, za potencijalno dobivanje ingenioznih informacija koje uzrokuju budući razvoj i organizaciju promatranog proizvodnog sustava.

6.2. Kritika postojećih mjera informacije procesnih obrazaca

Kod kratkih serija prikupljenih podataka vjerojatnost koju aproksimiraju relativne frekvencije pojava znakova ne smiju se uzeti kao pouzdane. Katkada nema niti apriorne informacije o prilježćoj statistici izvora kojeg promatramo. Čak je i još gore jer većina stvarnih proizvodnih procesa posjeduje stalnu vrijednost informacijskog signala sa superponiranim malim iznosom smetnje nepoznatog porijekla. Ovo je posljedica visoke automatizacije procesa pri čemu se pojedine kritične točke procesa automatski namještaju i drže na željenim iznosima. Kolebanja ovih iznosa su katkada i tri do četiri reda veličine manji od iznosa namještene vrijednosti i često se odvijaju u unaprijed zadanim vrlo uskim granicama. S druge strane pak procesi iskazuju standardne procesne obrasce koji predstavljaju očekivana stanja postrojenja. Ovi obrasci ne slijede nijednu poznatu statističku distribuciju pa se izmiču mogućnosti određivanja relevantne informacijske mjere. No oni se izmiču i svojoj nominalizaciji koji mogu izvesti procesni eksperti, a kojima bi se procesne veličine iz područja numeričkog obilježja preslikali u područje nenumeričkog, kvalitativnog opisa. Ovime smo dovedeni u situaciju da se u proizvodnji tako izbjegava ikakva mogućnost kvalitativno-kvantitativnog obuhvata procesnih veličina.

Dakle, informacijski opis postrojenja ne može striktno slijediti Shannonov koncept informacijske entropije zbog evidentne determinističke strukture koja rezultira „informacijskim bijelim mrljama“. Stoga se s pravom postavlja pitanje kako povezati Lernerov koncept informacijske makrodinamike, tako nužan u skladno vođenom procesu, sa stvarnim izvorima informacije u datom proizvodnom postrojenju, kojemu je to poznavanje neophodno potrebno zbog diktata vođenja procesa kvalitete prema TQM [134].

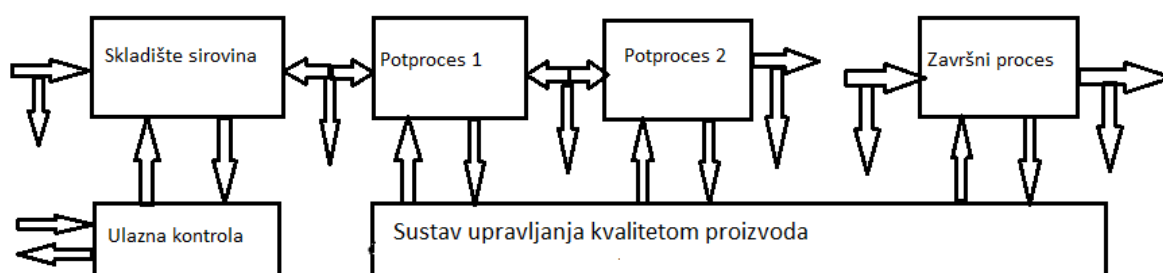
6.3. Reproducibilnost kvalitete proizvoda

Reproducibilna kvaliteta proizvoda primarni je interes industrijskog proizvođača. Osnovne akcije u kontroli kvalitete u proizvodnji danas se određuju dobro stratificiranom informacijskom strukturom poznatom kao sustav kontrole kvalitete [108], [135], [136]. U cilju osiguranja odgovarajućih odluka u funkciji sustava kontrole kvalitete uvodi se primjereni sustav prikupljanja i obrade podataka kojim se može pratiti kvaliteta proizvoda keramičkih pločica [137], [138], [139], [140], [141].

U ovome sustavskom pristupu postoje dvije osnovne prepreke: priroda mjerenog signala i odnos mjerenog signala i konačne kvalitete proizvoda. Prema samoj prirodi signala postoje kvantitativni i/ili kvalitativni signali, a s obzirom na odnos signala i pripadne kvalitete proizvoda postoje više manje posredni pokazatelji koji ukazuju na pravu prirodu veze između signala tražene kvalitete konačnog proizvoda. Razvoj nadzora kvalitete mora sve spomenute vidove problema uzeti u obzir.

Razvoj specifične sheme kontrole kvalitete u keramičkoj industriji uključuje sveobuhvatni nadzor osnovnih procesnih parametara u etapi pripreme materijala za dobivanje materijalnog supstrata, etapi mljevenja, izrade emulzije (šlikera), izrade klinkera, predsušenja, sušenja, prešanja, dosušivanja, glaziranja, dekoriranja, pečenja, kao i u kontroli kvalitete sudobavljača. Uvode se stanoviti postupci automatske inspekcije gotovih proizvoda, no konačnu odluku o kvaliteti proizvoda još uvijek donose posebno školovani i izvježbani radnici [39], [103], [104].

Bez obzira na sve finese procesa današnja proizvodnja keramičkih pločica je visoko automatiziran i robotiziran proizvodni kompleks. No čim više je taj proces automatiziran, time više konačni proizvod ovisi o kvaliteti u njemu angažirane radne snage. Ovo je osobito kritično kada radna snaga nije osobito motivirana za svoj radni učinak, Dodatak C. Tako u proizvodnji postoji sveobuhvatna shema kontrole kvalitete prikazana na slici 6.1 [136], kao apstrakcija sheme sa slike 6.4. Kako se može vidjeti sa sheme na slici 6.1 tokovi materijala i tokovi kontrole kvalitete teku u suprotnom smjeru. Dok tok materijala na spomenutoj slici teče slijeva udesno tok kontrole kvalitete teče s desna ulijevo. Uloga radnika jest da intervenira čim prije je moguće u proizvodni proces, da mijenja stvarne iznose kontrolnih signala, i da poduzima sve moguće akcije na koje upućuju signali kontrole kvalitete u procesu.




Slika 6.1. Shema sveobuhvatne kontrole kvalitete u proizvodnom procesu. Mjerni signali kvalitete i izvršni/kontrolni signali procesa naznačeni su strelicama od/i prema pojedinim procesnim dijelovima

6.4. Signali i kontrolni postupci u kontroli kvalitete keramičke proizvodnje

Klasična shema vođenja kvalitete industrijskih proizvoda, poput sheme vođenja kvalitete miješanja, može se primijeniti u procesu vođenja kvalitete izrade keramičkih pločica na postupke sušenja, glaziranja i dekoriranja, budući da se radi o složenoj pripremi kvalitete smjesa koje moraju odgovarati po svojem konačnom fizikalno-kemijsko-dekorativnom sadržaju. Procesi kontrole kvalitete pri prešanju ovise o ulaznom materijalu te o mnogo parametara podešenja preše poput temperature alata za otpresak, dimenzijama pločica, sili prešanja i sl. Kvaliteta

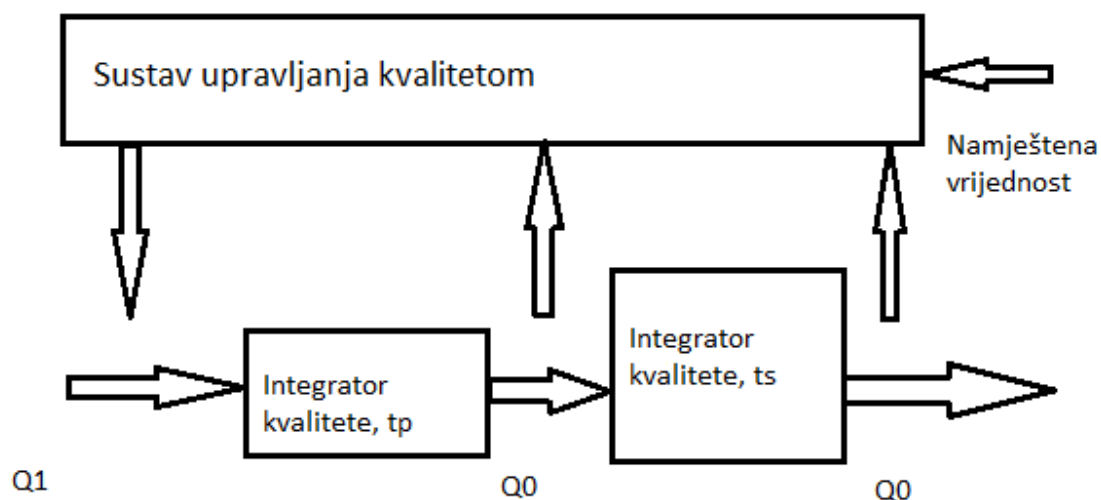
procesa pečenja ovisi o složenim međudjelovanjima temperaturnih profila peći, keramičkoj podlozi i svojstvima materijala za glaziranje i dekoraciju.

Opća strategija kontrole kvalitete zahtijeva što je više moguće nadzirati proces prije same obrade. Kod miješanja se kontrola provodi nakon svakog stupnja obrade pa se dobiva dijagrama toka signala kao što je prikazan na slici 6.2.



Slika 6.2. Dijagrama toka kontrole signala kvalitete sa slike 6.1. Vremenske konstante t_1, \dots, t_{RM} određuju specifični procesni dijelovi

Kada se kontrolni signal kvalitete s vremenskom konstantom τ_s nadzire s kraćom vremenskom konstantom τ_p dobiva se poboljšanje kvalitete izlaznog proizvoda s faktorom B jednakim $B = \frac{\tau_s}{\tau_p}$ [136]. Vremenska konstanta signala kontrole kvalitete τ_p treba se postaviti na iznos koji je najmanje pet do deset puta veći od najveće vremenske konstante dinamike mjerne i kontrolne opreme [136]. Na ovaj se način postiže integralno bolje djelovanje kontrole kvalitete konačnog proizvoda, što je osobito naglašeno kod postupaka izrade klinkera, glaziranja, dekoriranja i pečenja. Ovaj je način poboljšanja kvalitete proizvoda dan shematski na slici 6.3.




Slika 6.3. Dvostupnjeviti postupak u sustavu kontrole kvalitete proizvoda

6.5. Signali kontrole kvalitete u proizvodnji keramike prešanjem

Proces nadzora kvalitete u proizvodnji keramičkih pločica prešanjem prikazan je shemom na slici 6.4. Popis i opis signala kontrole kvalitete prikazan je u tablici 6.1. Pregled mjernih vrijednosti procesnih signala kvalitete i signala izlazne kvalitete dan je u Dodatku A.

KONTROLNE TOČKE U PROCESU PROIZVODNJE - PREŠANJA



Slika 7.

Slika 6.4. Kontrolne točke u procesu proizvodnje prešanjem

Tablica 6.1. Popis i opis signala kontrole kvalitete u pogonu proizvodnje keramike prešanjem

R.br	Naziv	Opis	Područje procesa	Napomena
1.	S1	Signal litarske težine šlikera na atomizeru	Proizvodnja šlikera	Izlazni signal iz silosa
2.	S2	Signal litarske težine šlikera na pet mlinova	Proizvodnja šlikera	Ulazni signal u silose
3.	S3-S9	Signali s granulometrije	Razdioba veličina granula pred prešama	Ulazni signali za preše
4.	S10	Kontrola vlage granulate	Postotak slobodne vode u granulate	Ulazni signal za preše
5.	S11	Kontrola temperature alata gornja matrica	Preše	Kontrolni signal preše
6.	S12	Kontrola temperature alata donja matrica	Preše	Kontrolni signal preše
7.	S13	Kontrola temperature rame	Preše	Kontrolni signal preše
8.	S14	Kontrola temperatura ulja	Preše	Kontrolni signal preše
9.	S15	Tlak ulja hidraulike	Preše	Kontrolni signal preše
10.	S16-S20	Debljine između rebara	Preše	Kontrolni signali geometrije preše
11.	S21-S25	Debljina preko rebara	Preše	Kontrolni signali geometrije preše
12.	S26-S30	Klinavost između rebara	Preše	Kontrolni signali geometrije preše
13.	S31-S35	Klinavost preko rebara	Preše	Kontrolni signali geometrije preše
14.	S36-S40	Čvrstoća otpreska	Izlaz pločica	Kontrolni signali mehaničkih svojstava pločice
15.	S41	Glaziranje – litarna težina	Glaziranje	Kontrolni signal glaziranja

16.	S42	Glaziranje – nanos	Glaziranje	Kontrolni signal glaziranja
17.	S43	Glaziranje- viskozitet	Glaziranje	Kontrolni signal glaziranja
18.	S44-S47	Krivulja maksimalne temperature paljenja peći – prvi kanal	Tunelske peći	Kontrola temperaturnog profila pečenja
19.	S48-S51	Krivulja maksimalne temperature paljenja peći – drugi kanal	Tunelske peći	Kontrola temperaturnog profila pečenja
20.	S52-S54	Signali postotka sirovog škarta sa sortir linija II, IV i V	Sortir linije	Završna kontrola proizvoda
21.	S55	Ukupni signal sirovog škarta	Sve sortir linije	Završna kontrola svih proizvoda

Kako je vidljivo proizvodni proces za izradu keramičkih pločica generira gotovo isključivo numeričke podatke. Podaci se prikupljaju uglavnom ručno na dnevnoj i/ili smjenskoj osnovi od strane osoblja zaduženog za kontrolu kvalitete proizvodnje. Informacijski sadržaj podataka s navedenih mjernih točaka ukazuje na stvarno stanje kvalitete u proizvodnji budući da se svako odstupanje od navedenih vrijednosti smatra odstupanjem od zahtijevane kvalitete proizvoda i može rezultirati u višestrukim proizvodnim gubitcima. Dakle ne samo sam informacijski sadržaj signala već i postignuti brojevi iznosi pojedinih signala su od važnosti za kontrolu kvalitete i konačnu kvalitetu proizvoda. Oni su, dakle, kontrolna i ciljna funkcija kvalitete. Budući da se radi o signalima koji su definirani često u vrlo uskim granicama tolerancije, koja na promjer za temperaturne signale s peći iznosi između 0,1 % i 0,5%, i cjelovito su povezani s nepoznatim konačnim učinkom na kvalitetu proizvoda to je njihovo poznavanje i međudjelovanje od odlučujuće važnosti za kvalitetu konačnog proizvoda.

6.6. Model sustava upravljanja kvalitetom

Model sustava upravljanja kvalitetom nastaje superpozicijom pojedinih potprocesa upravljanja kvalitetom na način da je pojedini potproces predstavljen odgovarajućim informacijskim sadržajem vezanim za ciljno ostvarenje proizvodnje-kvalitetom proizvoda: njegovim jednoznačnim kodom i iznosom pripadajuće entropije. Provedeni model dakle zahtijeva da se postavljeni parametri kvalitete određuju u okviru preporuka proizvođača opreme što znači za svaki obročni proizvod odvojeno. Tijek praćenja procesa kvalitete ima prema slici 6.2 smjer suprotan tijeku proizvodnog procesa, čime samo ukazuje na nemogućnost, ireverzibilnost popravka kvalitete proizvoda. Stoga se u skladu s vremenskim konstantama pojedinog dijela obročne proizvodnje moraju izvoditi i kontrole odnosno upravljati kvalitetom procesa proizvodnje.

Pregled konkretnog sustava upravljanja kvalitetom u proizvodnji keramike dan je u dodatku B,

„Pregled proizvodnje i kontrole kvalitete u KIO Orahovica“

Pojave škarta koje su opažene mjerenjima u dijelu 5. imale su međutim djelovanje koje se protezalo unutar tri ili četiri smjene, dakle mogla su se postići poboljšanja s idealnim faktorom 3 do 4.

Analizirani postupci prešanja i pečenja međutim imaju relativno veće osjetljivosti na smetnju i shema sa slike 6.3 na njih se ne može u potpunosti primijeniti. Ukoliko dakle pratimo informacijske obrasce prema postupku izloženom u dijelu 5. onda možemo postupiti na dva načina:

- a) Konzervativno reagirajući na pojavu škarta iznad 6%, prema izloženom u dijelu 5 te tako dovodimo do određenih poboljšanja
- b) Preventivno reagirajući na pojavu škarta na daleko nižoj razini od 5,5% ili 5%.

U oba slučaja potrebno je provoditi organizacijske zahvate koji uključuju

- a) Pravodobno prikupljanja smjenskih podataka kvalitete i škarta
- b) Obrada smjenskih podataka prije nastupa nove smjene
- c) Reagirajući preventivno na pojavu indikacije kvarova u pogonu zahvatom u uzroke tih pojava – nad- ili pod-temperatura kod peći te neispravne montaže alata kod preša.

Niže prikazujemo jednu konzervativnu procjenu financijskog gubitka škarta iznad 6% u tvrtci KIO Keramika za 2008 godinu.

Planirani dozvoljeni škart u KIO Keramika d.o.o. na ukupnu proizvodnju iznosi 6% te će se na osnovu proizvodnje u 2008. godini iskazati financijski gubitak škarta iznad dozvoljenog planiranog škarta. Pošto je škart za 2008. kumulativno premašio planirani dozvoljeni škart od 6% i iznosi 8,9% što je za 2,9% više, iskazuje se financijski gubitak na osnovu prosječne proizvodne prodajne cijene od 38,12 kn/m².

Predana proizvodnja keramičkih pločica za unutrašnje i vanjsko oblaganje za 2008. godinu iznosi 6.159.501,97 m². Jednostavnim matematičkom formulom dobije se gubitak prekomjernog škarta u m² kako slijedi:

Izračun prekomjernog škarta u m² kako slijedi:

Predana proizvodnja pomnožena s postotkom prekomjernog škarta jednaka je količini škarta u m², odnosno

$$6.159.501,97 \times 2,9\% = 178.625,56 \text{ m}^2$$

Predana proizvodnja pomnožena s postotkom prekomjernog škarta i prosječnom prodajnom cijenom daje financijski gubitak zbog škarta u kunama

$$6.159.501,97 \times 2,9\% \times 38,12 \text{ kn} = 6.809.206,24 \text{ kn}$$

Da je škart bio planiranih 6% proizvodnja bi bila uvećana za 178.625,56 m², a financijski dobitak bio uvećan za 6.809.206,24 kn.

Preventivna organizacija kontrole kvalitete s niže postavljenim zahtjevima na dozvoljeni škart tražila bi uz ostalo dogovor s proizvođačima strojeva oko opremanja novim indikatorima kontrole kvalitete, novu organizaciju službe kontrole kvalitete i uvođenje ekspertnih on- line ocjena stanja kvalitete pojedinog dijela proizvodnje. Ovo bi svakako bio zamašan zadatak za cijeli stručni i menadžerski tim, pri čemu treba trajno voditi računa o motiviranosti svih proizvodnih radnika što u našem slučaju nije bio slučaj, Dodatak C „Analiza motiviranosti radnika u KIO Keramika“.

7. RASPRAVA

Industrijska se proizvodnja odvija u uvjetima visoke konkurentnosti. Ovo zahtijeva da se uz stalnu brigu oko ekonomičnosti vodi računa o poboljšanju učinkovitosti proizvodnog procesa, kvalitete, te smanjenju škarta. Današnja proizvodnja je visoko automatizirana i robotizirana te izuzetno učinkovita. Svako i najmanje odstupanje u radu strojeva dovodi do škarta, te je stoga neobično važno postići sinergiju rada menadžmenta, zaposlenika i strojeva [142], [114]. Osnovicu pristupa otkrivanja potencijalnih mjesta kvarova s pomoću kodiranja procesnih obrazaca bila je činjenica da statističke obrade podataka nije smjelo niti moglo biti jer se na striktno vođenim, strogo kontroliranim i povratnom vezom fiksiranim proizvodnim podacima nikakva uobičajena statistika nije niti mogla očitovati, vidjeti prilog A, što potvrđuje analiza dobivenih entropijskih mjera za Ishikawa podobnu analizu mjernih signala kontrole kvalitete u prilogu E.

U ovom su radu razmatrane dvije rizične spona učinkovite proizvodnje: procesi na utvrđivanju procesnih smetnji koje dovode do škarta i cjelovitost provedbe poboljšanja po njegovom pravodobnom otkrivanju, dakle razmatrana je cjelina proizvodnog procesa [143], [144], [145], te njen posredni učinak na kvalitetu konačnog proizvoda [146].

7.1. Rasprava o proizvodnom procesu i pravodobnoj detekciji škarta

Logička ideja da se iskoriste procesni signali proizvodnje kako bi se omogućio nadzor i upravljanje kvalitetom u proizvodnji vezana je s odgovarajućim objašnjenjem značenja procesnih signalnih obrazaca [143]. Objašnjenje da svaka signalna veličina mora biti „kao što je zadana od proizvođača stroja“ postaje izvor dvosmislenosti kada proizvodnja određenog proizvoda traži procesna podešavanja ili kada se dogodi prirodna promjena procesne veličine zbog manipulatorne greške u pripremi stroja ili procesna smetnja zbog npr. greške u dobavi energije, promjeni temperature i vlage okoliša proizvodnje.

Općenito promatrano, kada se procesni signali ispravno odaberu, prate i podešavaju tada je mjerena kvaliteta proizvoda niža od postignute kvalitete svake zasebne proizvodne faze. Ako bi kvaliteta proizvoda bila veća od kvaliteta zasebnih fazi proizvodnje tada se možemo zapitati ne radi li se o za kvalitetu loše odabranim odnosno irelevantnim signalima. Za signale koji su irelevantni, ali precizniji od konačnog proizvoda se QC proces nepotrebno komplicira. Za kontrolu kvalitete dostupna su oba pristupa: ili raspolaganje ekspertnog objašnjenja signalnog iznosa ili dobivanje mjere djelovanja određenog signala na kvalitetu izlaznog proizvoda [108], [149], [103].

Rješenje pitanja visoke osjetljivosti na male promjene zbog nazočnosti šuma u kodnim segmentima bez promjene bila bi primjena određene logike kojom bi se te smetnje ispod određene razine smatrane nevažnima. Određivanje ovih razina neosjetljivosti na smetnju je procesno ovisno i zahtijeva brižno ispitivanje promjena iznosa signala te konzultaciju s ekspertima prije određivanje teselacijske entropije. U slučaju promatranog skupa mjerenja u trajanju od devedeset dana promjene koje su se dogodile na najnižoj znamenki očitavanja bile su očigledne. Nikakav se šum nije mogao pronaći u njima (prilog A). Također bilo je mnogo konstantnih očitavanja. Zbog ove očite neosjetljivosti raspoloživih industrijskih procesnih mjerenja, odlučeno je da se svaka procesna vrijednost smatra relevantnom pri njezinoj kodnoj pretvorbi u znak proširenim teselacijskim postupkom.

Ekspanzija jedno-dimenzijske entropije popločenja procesnih signala, kao što je navedena u poglavlju 5, primjenjiva je na kvantitativne podatke. Analiza ove entropijske ekspanzije zadovoljava potrebe sustava automatskog praćenja mjerne pogonske informacije. Teleonomski karakter ekspanzirane teselacijske entropije omogućava korisniku utvrđivanje obrazaca onih malih odsječaka signalnih mjerenja, u inače uglavnom slabo koreliranim podacima, koji daju usporedive obrasce ponašanja signala s proizvodnih strojeva i završne kontrole kvalitete proizvoda. Ova entropija kvantificira podatkovne razlike procesnih signala ispitivanjem slijednih četvorki mjernih iznosa signala. Jedinstveni 27-znakovni kod iz tablice 5.3 osigurava različite entropijske iznose za svaku moguću varijaciju procesnog signala izmjerenog u četiri uzastopna

mjerna uzorka. Dakle manji broj slijednih mjerenja vodio bi u neosjetljivost, a veći od četiri u zaostajanje u primjenjivosti navedenog postupka. Ipak bogatstvo generacije obrazaca ekspanzijom obrazaca mjernog ternarnog koda dano izrazom (2.3) daleko premašuje dosege ove primjene.

7.2. Rasprava o primjenjivosti postupka u proizvodnom procesu i ekonomičnosti provedbe

U našem se slučaju skup mjernih podataka promjene događaju na najnižem decimalnom mjestu i bile su osmotrive i očite. No šum u smjenskim podacima nije postojao. Također postojalo je mnoštvo istovrsnih mjerenja. Zbog ove očigledne neosjetljivosti danog industrijskog mjernog procesa odlučili smo se da bi u našem slučaju bilo razumno da svaku promjenu bilo koje QC kontrolne veličine smatramo relevantnom pri kodiranju signala u 27-znakovnu procesnu abecedu. Pri tome je jednodimenzijska teselacijska entropija kako je predložena u dijelu 5. rada primjenjiva na procesne kvantitativne podatke. Analizirana i prikazana metoda podesna je za zadovoljavanje zahtjeva informacijske mjere u ovom visoko automatiziranom i robotiziranom pogonu. Statističke metode dobivanja obrazaca poput PCA ne bi bile primjenjive jer zahtijevaju nekoliko puta veći broj snimaka od broja varijabli [150], pa bi već za kritične varijable preše njih deset tražilo pedesetak mjerenja što bi bilo neprimjenjivo.

Teleonomski, ciljni, značaj proširene teselacijske entropije podataka omogućuje korisniku pristup kratkim segmentima ovih inače gotovo nekoreliranih podataka kako bi pronašao sukladne obrasce podataka. Ova entropija kvantificira podatkovne razlike procesnih signala kontrole kvalitete tako da ispituje četvorku po četvorku u posmaku mjerenja pojedinog signala. Jedinstvena 27-znakovna abeceda iz tablice 5.3 osigurava različite entropijske iznose za svaku moguću promjenu u mjerenju procesnog signala.

U ovom radu analiza je ograničena na situacije u kojima se ista kodna shema znakova pojavljuje i u mjernom signalu i u signalu završne kvalitete kontrole. Ovakav slučaj ima jasnu interpretaciju: oba se signala ponašaju na isti način u istom vremenskom segmentu i zbog toga su možda u određenoj relaciji. Stupanj te relacije mjeri se entropijom. No svakako mogla bi se

uključiti i mogućnost relacije među 'suprotnim' znakovima u smislu da kada se jedan znak ponaša suprotno od drugog postoji određena mogućnost suprotstavljene relacije. No zamijetimo da je suprotnost u ponašanju ekspanziranog mjernog podatka već obuhvaćena ekspanzijom kodnih pravila i odatle i njihovih entropija. Na primjer znak B (00+0++) i C (00-0--) iz tablice 5.3 su suprotno postavljeni znakovi. Provedeno je istraživanje utjecaja suprotnih znakova, međutim u našem slučaju izgleda da su od značaja samo originalni znakovi, a ne i njihovi 'inverzi'. Ovo može biti osobina proučavanog procesa, ali ovime se ne diskvalificira metoda suprotnih znakova iz analize skupa mjerenja.

Valja zamijetiti da osnovna pretpostavka navedene metode tj. obrada procesnih podataka koji su najbliži podacima izlazne kvalitete proizvoda s obzirom na oblik, koji ti signali poprimaju, te njima pripadajuće ekspanzirane entropije kao najvjerojatnijem mjestu kvara, ne mora vrijediti u određenim situacijama. Posebno ako izlazni signal odražava utjecaje drugih vanjskih varijabli osim ovih koje su mjerene.

Očigledno je metoda primjenjiva samo na signale koji su analizi na raspolaganju. Izrada i primjena tehnologije impaktograma na vođenje kvalitete izlaznog proizvoda se za sada provodi ručno – budući da se radi o smjenskim mjerenjima ovi nedostaci se mogu smatrati neutjecajnim na konačnu kvalitetu odluke QA službe. Automatska interpretacija procesnih događaja je otežana iz dva razloga: a) značenje signala koji je mogao uzrokovati nepoželjan učinak ili koji je mogao biti ogledalo takvog učinka ne može se lako razumjeti od strane nekog inteligentnog stroja, i b) razine sličnosti teselacijskih entropija procesnog signala i QC signala nisu jednostavne za postavljanje. Prvi problem mogao bi se djelomično riješiti obilježavanjem signala tako da oni predstavljaju potencijalni uzrok kvarova, čija se mogućnost ispituje dalje u daljinskoj bazi znanja.

Drugi problem je zanimljiv s teorijskog stajališta i također je procesno ovisan. Naime pri određivanju ispravne razine odluke, postoji pitanje drugih funkcijskih svojstava QC koje se ne mjere u relevantnim trenucima uzorkovanja. Svejedno bi valjalo poduzeti odgovarajuće akcije u prikupljanju spomenutih procesnih podataka i pripravi za izradu ekspertne baze znanja koja bi

uzela u obzir i spomenute razine odluke. S ovakvim poznatim ograničenjima na procesnim signalima moguće je implementirati spomenutu tehniku teselacijake entropije i na druge proizvodne pogone. On-line nadzor procesa bi omogućio tada da se s praćenjem relevantnih procesnih signala izvede QC i u stvarnom vremenu. No za on-line primjenu i sa velikim brojem signalnih mjerenja može se izvesti odgovarajuća kontrola kvalitete i s pomoću Shannonove entropije.

Interpretacija impaktograma se do sada primjenjivala samo u pokusnom slučaju. Mišljenja sam da se automatizacija procesa interpretacije može teško primijeniti zbog dvaju razloga: 1) značenje signala koji su mogući uzroci nepogodnog procesnog događaja ne mogu se lako protumačiti stroju; 2) određivanje prave razine sličnosti procesnih signala i QC signala putem sličnosti njihovih proširenih teselacijskih entropija koja bi sugerirala tu povezanost. Prvi problem može se djelomično otkloniti obilježavanjem signala koji su potencijalni uzrok kvarova, njihovih učinaka i veza, što bi bilo moguće korištenjem baze znanja koja bi uključivala hijerarhijsku semantiku poput ontologije na strojevima vezanim za računala proizvođača strojeva za keramiku. Drugi problem je zanimljiv s teorijske perspektive i također je vjerojatno procesno ovisan. Odgovarajući smjer akcije bio bi prikupljanje podataka o procesu i oblikovanje konsenzusa ekspertnih mišljenja s obzirom na razinu razlike entropija koju bi se smatralo primjerenom.

Uzevši u obzir ova ograničenja predloženi postupak određivanja poboljšanja QC procesa može se primijeniti na bilo koji industrijski proces u kojem se prikupljaju procesni podaci, a koji je poznat po povremenim pogreškama odnosno defektima u proizvodnji. Implementacija teselacijske entropije može se računarski izvesti u bilo kojem jeziku poput C ili Java, a vizualizacija impaktograma može se najbolje izvesti uporabom tabličnih procesora poput Microsoft Excel ili OpenOffice Calc. Besprekidno (engl. *on-line*) nadgledavanje može se omogućiti kada se prikupe relevantni procesni podaci u stvarnom vremenu a ne jednom u smjeni. U potonjem slučaju provodi se naknadna analiza (engl. *off-line*) i pokazalo se kao dostatna za prikazani primjer. Ostaje za daljnje utvrđivanje je li predložena metoda u otkrivanju

uzroka kvarova bolja od Shannonove entropije za slučaj velikog broja događaja kvara u online prikupljanju procesnih mjerenja. Za slučaj „uhodavanja“ procesa u razvojnom postupku razrade postrojenja, statistička metoda je nezaobilazna [149].

8. ZAKLJUČAK

Kvantitativno istraživanje parametra kvalitete proizvoda dalo je rezultate koji se u velikoj mjeri poklapaju sa stvarnom i zatečenom situacijom u tvrtki prema mišljenju autora ovoga istraživanja i svojedobnog menadžera obročne industrijske proizvodnje. Štoviše, kvantificiranje, analiza i sinteza inače «nečitljivih» kvalitativnih podataka službe kontrole kvalitete zaista daje puno preciznije smjernice potrebnog djelovanja menadžmenta u svrhu optimizacije poslovnih procesa. Stoga možemo zaključiti da je

- a) praćenjem parametara kvalitete u okviru preporuka proizvođača opreme i djelovanja službe kontrole kvalitete moguće pronaći utjecajne veličine na kvalitetu proizvoda

Predložena metoda računanja informacijskog sadržaja obrazaca procesnih signala u automatiziranoj i robotiziranoj obročnoj proizvodnji keramičkih pločica na osnovici 27 znakovnog koda mjernih signala je jednostavna i daje brze rezultate s malim zahtjevima na njihovo izdvajanje iz postojećeg proizvodnog procesa. Ova metoda određivanja varijabilnosti sadržaja signalnih mjerenja zasniva se na zamisli jednodimenzijske ekspanzirane teselacijske entropije kojom se uzima procesno mjerenje u uzorcima pomičnog okvira sa četiri zadnja procesna uzorka te se iz svih suodnosa njihovih veličina računa sadržaj teselacijske entropije. Pokazano je da se ova jedinstvena informacijska mjera može primijeniti na automatizirani proizvodni proces istodobnim interpretiranjem kodnog rezultata što ih pojedini procesni signal ima na ponašanje kodnog rezultata varijable izlazne kvalitete proizvoda. Ova se interpretacija znakovnog i entropijskog sadržaja pokazala mogućim alatom u pronalaženju pobude i učinka, dakle mogućeg uzroka i posljedice nalaženja grešaka u automatiziranoj proizvodnji keramičkih pločica. Iznaženje stroja koji je prouzročio kvar promatranjem njegovih po službi kontrole kvalitete odabranim mjernim signalima, dakle koji segment ponašanja stroja je bio najutjecajniji za to ponašanje te koje su posljedice ovakvog njegovog ne/podešavanja, presudno je u automatiziranoj visokoproduktivnoj proizvodnji, budući da onemogućava ovakve događaje u

budućoj proizvodnji zaustavljanjem i prepodešavanjem stroja ili premještanjem proizvodnje na druge strojeve. Ujedno se može preispitati kvaliteta pripreme i podešavanja stroja prije ulaska u pogon te eventualno obaviti konzultacije s radnicima zaduženim za podešavanje i pripravu, sa službom kontrole kvalitete koja određuje radne parametre stroja te eventualno obaviti konzultaciju i s proizvođačima strojeva. Pokazalo se da je predložen postupak u prednosti pred jednostavnijom korelacijskom metodom jer prati vremensku varijantnost procesnog signala.

Stoga se druga hipoteza

- b) Analizom kodnog obrasca utjecajnih veličina procesa pomoću ekspanirane 1D Carnapove entropije moguće je pravodobno otkriti mjesto nastanka poremećaja procesa proizvodnje

pokazala ostvarivom.

Prikazana analiza može biti od koristi pri vođenju postupaka nadzora kvalitete u automatiziranoj šaržnoj proizvodnji kada kvaliteta izlaznog proizvoda iskazuje odgovarajuću dinamiku koja izmiče standardnoj kontroli kvalitete, ali i šire pri određivanju stanja teleonomičnosti nekog visokoautomatiziranog proizvodnog procesa s promjenjivim procesnim ishodom. Odgovarajućom organizacijom brzog prikupljanja o obrade podataka jednodimenzijske ekspanirane Carnapove entropije u keramičkoj industriji moguće je znatno djelovati na bolju ekonomičnost i odatle konkurentnost pogona.

Stoga se treća hipoteza

- c) Otklanjanjem otkrivenih poremećaja moguće je poboljšati ekonomičnost automatizirane proizvodnje u keramičkoj industriji.

pokazala ostvarivom.

LITERATURA

- [1] Wiener, N., *The Human Use of Human Beings – Cybernetics and Society*, Avon Books, New York, 1967, pp 13-14.
- [2] Shannon C. E., *A mathematical theory of Communication*, B.S.T.J., part I and II (July 1948) part III, IV and V (October 1948).
- [3] Bertalanffy, L. von, (1969), *General System Theory*. New York: Georg Braziller, str. 39-40.
- [4] Popper K, *In Search of a Better World*. Routledge, 2000, ISBN 0-415-13548-6, str. 46.
- [5] Myron Tribus, *Quality first: Selected Papers on Quality and Productivity Improvement*, National Society of Professional Engineers, 1987, ISBN 0731629167, 9780731629169.
- [6] <http://www.fmea-fmeca.com/fmea-rpn.html>.
- [7] Lavinia A., Dobre C., Pop F, Cristea V. *A Failure Detection System for Large Scale Distributed Systems*. CISIS International Conference on Complex, Intelligent and Software Intensive Systems 15-18-Feb. 2010 Krakow, 482-489, ISBN 978-1-4244-5917-9, DOI 10.1109/CISIS.2010.29, INSPEC accession number 11258956].
- [8] Slišković, D., Grbić R., Hocenski Ž. *Adaptive Estimation of Difficult –to –Measure Process Variables*. *Automatika*. 54 (2013), 2; 166-177.
- [9] Arvanitoyannis, I.S, Varzakas, T.H. *Application of ISO 22000 and Failure Mode and Effect Analysis (FMEA) for Industrial pProcessing of Salmon: A Case Study*. *Critical Reviews in Food Science and Nutrition*, 48:411-429 (2008) ISSN: 1040-8398, DOI: 10.1080/10408390701424410.
- [10] Kondo, Yoshio (July 1994). "*Kaoru Ishikawa: What He thought and Achieved, A Basis for Further Research*". *Quality Management Journal* 1 (4): 86–91. [ISSN 1068-6967](#).
- [11] Kolmogorov, A. (1968). "Logical basis for information theory and probability theory". *IEEE Transactions on Information Theory* 14 (5): 662–664. [doi: 10.1109/TIT.1968.1054210](#).
- [12] Cysarz, D., Lange, S., Matthiessen, P. F., & van Leeuwen, P. (2007). Regular Heartbeat Dynamics Are Associated with Cardiac Health. *American Journal of Physiology, Regulatory, Integrative and Comparative Physiology*, 292(1), R368-R372. doi:10.1152/ajpregu.00161.2006.
- [13] Cysarz, D., Bettermann, H., & van Leeuwen, P. (2000). Entropies of Short Binary Sequences in Heart Period Dynamics. *American Journal of Physiology, Heart and Circulatory Physiology*, 278,6, H2163-H2172.

- [14] Yang, A. C. C., Hseu, S. S., Yien, H. W., Goldberger, A. L., & Peng, C. K. (2003). Linguistic Analysis of the Human Heartbeat Using Frequency and Rank Order Statistics. *Physical Review Letters*, 90(10), 108103. doi: 10.1103/PhysRevLett.90.108103.
- [15] Bogunovic, N., & Smuc, T. (2008, June). Applicability of Qualitative ECG Processing to Wearable Computing. In Y.-T. Zhang (Chair), *Proc. 5th Int. Summer School and Symposium on Medical Devices and Biosensors (ISSS-MDBS)*, Hong Kong, China, 133-136.
- [16] Zhang, X. S., Zhu, Y. S., Thakor, N. V., & Wang, Z. Z. (1999). Detecting Ventricular Tachycardia and Fibrillation by Complexity Measure. *IEEE Transactions on Biomedical Engineering*, 46(5), 548-555. doi: 10.1109/10.759055.
- [17] Bandt, C., & Pompe, B. (2002). Permutation entropy: a natural complexity measure for time series. *Physical Review Letters*, 88(17), 174102. doi:10.1103/PhysRevLett.88.174102.
- [18]]Hornero, R., Abasolo, D., Jimeno, N., Sanchez, C. I., Poza, J., & Aboy, M. (2006). Variability, Regularity, and Complexity of Time Series Generated by Schizophrenic Patients and Control Subjects. *IEEE Transactions on Biomedical Engineering*, 53(2), 210-218. doi: 10.1109/TBME.2005.862547.
- [19] Xu, J., Liu, Z., Liu, R., & Yang, Q. (1997). Information Transformation in Human Cerebral Cortex. *Physica D*, 106(3-4), 363-374.
- [20] Baumert, M., Baier, V., Truebner, S., Schirdewan, A., & Voss, A. (2005). Short- and Long-Term Joint Symbolic Dynamics of Heart Rate and Blood Pressure in Dilated Cardiomyopathy. *IEEE Transactions on Biomedical Engineering*, 52(12), 2112-2115. doi: 10.1109/TBME.2005.857636.
- [21] Cysarz, D., Porta, A., Montano, N., van Leeuwen, P., Kurths, J., & Wessel, N. (2013). Quantifying Heart Rate Dynamics Using Different Approaches of Symbolic Dynamics. *European Physical Journal Special Topics*, 222(2), 487-500. doi: 10.1140/epjst/e2013-01854-7.
- [22] Kamath, C. (2012). A New Approach to Detect Congestive Heart Failure Using Sequential Spectrum of Electrocardiogram Signals. *Medical Engineering & Physics*, 34(10), 1503-1509. doi: 10.1016/j.medengphy.2012.03.001.
- [23] Porta, A., Baselli, G., Liberati, D., Montano, N., Cogliati, C., Gneccchi-Ruscione, T., Cerutti, S. (1998). Measuring Regularity by Means of a Corrected Conditional Entropy in Sympathetic Outflow. *Biological Cybernetics*, 78(1), 71-78.
- [24] Harikrishnan, K. P., Misra, R., & Ambika, G. (2009). Efficient Use of Correlation Entropy for Analysing Time Series Data. *Pramana*, 72(2), 325-333. doi: 10.1007/s12043-009-0028-5.

- [25] Wessel, N., Malberg, H., Bauernschmitt, R., & Kurths, J. (2007). Nonlinear methods of Cardiovascular Physics and Their Clinical Applicability. *International Journal of Bifurcation and Chaos*, 17(10), 3325. doi: 10.1142/S0218127407019093.
- [26] Faust, O., Acharya, R. U., Krishnan, S. M., & Min, L. C. (2004). Analysis of Cardiac Signals Using Spatial Filling Index and Time-Frequency Domain. *BioMedical Engineering OnLine*, 3, 30. doi: 10.1186/1475-925X-3-30.
- [27] Grassberger, P., & Procaccia, I. (1983). Estimation of the Kolmogorov Entropy from a Chaotic Signal. *Physical Review A*, 28(4), 2591-2593.
- [28] Pincus, S. M., & Goldberger, A. L. (1994). Physiological Time-Series Analysis: What Does Regularity Quantify? *American Journal of Physiology, Heart and Circulatory Physiology*, 266(4)(2), H1643-H1656.
- [29] Richman, J. S., & Moorman, J. R. (2000). Physiological Time-Series Analysis using Approximate Entropy and Sample Entropy. *American Journal of Physiology, Heart and Circulatory Physiology*, 278(6), 2039-2049.
- [30] Xie, H. B., Guo, J. Y., & Zheng, Y. P. (2010). Fuzzy Approximate Entropy Analysis of Chaotic and Natural Complex Systems: Detecting Muscle Fatigue Using Electromyography Signals. *Annals of Biomedical Engineering*, 38(4), 1483-1496. doi: 10.1007/s10439-010-9933-5.
- [31] Porta, A., Gnecci-Ruscone, T., Tobaldini, E., Guzzetti, S., Furlan, R., & Montano, N. (2007). Progressive Decrease of Heart Period Variability Entropy-Based Complexity During Graded Headup Tilt. *Journal of Applied Physiology*, 103(4), 1143-1149. doi: 10.1152/japplphysiol.00293.2007.
- [32] Seker, R., Saliu, S., Birand, A., & Kudaiberdieva, G. (2000). Validity Test for a Set of Nonlinear Measures for Short Data Length with Reference to Short-Term Heart Rate Variability Signal. *Journal of Systems Integration*, 10(1), 41-53. doi: 10.1023/A:1026507317626.
- [33] Pudmetzky, A. (2005). Teleonomic Entropy Measuring the Phase-Space of End-Directed System. *Applied Mathematics and Computation*, 162(2), 695-705. doi: 10.1016/j.amc.2004.01.006.
- [34] Fortune, S. (1987). A Sweepline Algorithm for Voronoi Diagrams. *Algorithmica*, 2(1-4), 153-174.
- [35] V.S. Lerner, *Information System Theory and Informational Macrodynamics: Review of the Main Results*. IEEE Transactions on Systems, Man and Cybernetics – Part C: Applications and reviews, 37 (6) (2007), 1050-1066.

- [36] A. D. Wyner, J. Ziv and A. J. Wyner, "On the Role of Pattern Matching in Information Theory", *IEEE Transactions on Information Theory*, vol. 44, no. 6, p. 2045-2078, 1998.
- [37] V. S. Lerner, "Information, models of evolution and cyclic functioning", *Syst. Anal. – Modelling – Simul*, vol. 42, no. 8, pp. 1167-1197, 2002.
- [38] A. Pudmetzky, *Teleonomic Entropy Measuring the Phase-Space of End-Directed System*. Applied Mathematics and Computation 162 (2) (2005), 695-705.
- [39] F. Jović, D. Krmpotić, A. Jović, V. Hocenski, N. Slavek, *Information Content of Process Signals in Quality Control*. The IPSI BgD Transactions on Internet Research. July 2008 Vol.4 No. 2 (ISSN 1820-4503), pp 10-16.
- [40] Jović F., Krmpotić D., Jović A. *Process entropy and informational macro-dynamics in a ceramic plant*. MIPRP 2009, 32nd Int. Convention, Proc. Opatija 2009, Conference: Computers in Technical Systems, ed. N. Bogunović, S. Ribarić. pp 50-53.
- [41] Robbins, S. P. (1995.), Bitni elementi organizacijskog ponašanja. MATE, Zagreb.
- [42] Brajša, P. (1993.), Menadžerska komunikologija. DRIP, Varaždin-Zagreb.
- [43] Sehanović, J., Žugaj, M. (1997.), Information technologies and organizational structure. *Library Management*, Volume 18, Number 2, 1997., pp. 80-87.
- [44] Fox, R. (2001.), Poslovna komunikacija. Hrvatska sveučilišna naklada, Zagreb.
- [45] Perrow, C. (1986.), Complex Organizations (A Critical Essay). Random House, New York.
- [46] Schein, E. H. (1996.), Organizational Culture and Leadership. Jossey-Bass, San Francisco.
- [47] Papoulis A., Probability, Random Variables and Stochastic Processes, McGraw Hill, N.Y., 1965.
- [48] Graupe D., Time series analysis, identification and adaptive filtering. Robert E. Krieger Publ. C., Malabar, Florida 1984, ISBN 0-88275-713-X.
- [49] Ž. Pauše, Vjerojatnost : Informacija, stohastički procesi : pojmovi – metode – primjene. Školska knjiga Zagreb 1988.
- [50] Brillouin L., Scientific Uncertainty and Information. New York, Academic Press 1956.
- [51] A.N. Kolmogorov, *Information Theory and Theory of Algorithms*. Nauka, Moscow, (1987).
- [52] Haken H., Information and Self-Organization. Berlin Germany: Springer Verlag 1988.
- [53] Landau L. D., Lifschitz E. M., Theoretical Physics. Mechanics. Moscow: Nauka, 1965.
- [54] van Kampen N.G. *Remarks on Non-Markov Processes*, Brazilian Journal of Physics, vol.28, no. 2, June 1998.

- [55] Feller, W. An Introduction to Probability Theory and its Applications, J. Wiley, New York, 1953.
- [56] R. Rosen, Fundamentals of Measurement and Representation of Natural Systems. Amsterdam, The Netherlands: Elsevier, 1978.
- [57] P. Grassberger and I. Proccacia, "Dimensions and Entropies of Strange Attractors From a Fluctuating Dynamics Approach", *Physica D*, vol. 13, issue 1-2, p. 34-54, 1984.
- [58] Cellier, F. E. (1996.), Mixed quantitative and qualitative modeling: means for dealing with system uncertainty. *15th Benelux Meeting on Systems and Control*, pp.111-123., Mierlo, Nizozemska.
- [59] Schein, E. H. (1999.), The Corporate Culture Survival Guide. Jossey-Bass, San Francisco.
- [60] ISO 9000:2015.
- [61] Funda, D.: *Upravljanje kvalitetom*, VVG, 2012.
- [62] Ishikawa, K. (1994): What He thought and Achieved, A Basis for Further Research. Quality Management Journal.
- [63] Mudronja V.: *Kontrolna karta – slika procesa*, FSB, Zagreb, Brioni, 2013.
- [64] Shewhart, W. A. (1931). *Economic Control of Quality of Manufactured Product*. ISBN 0-87389-076-0].
- [65] Shewhart, W. A. (1939). *Statistical Method from the Viewpoint of Quality Control*. ISBN 0-486-65232-7].
- [66] Mandel, B. J. (1969). "The Regression Control Chart". Journal of Quality Technology 1 (1), 1–9; Oakland, J. (2002). *Statistical Process Control*. ISBN 0-7506-5766-9.
- [67] Lloyd S. Nelson, *Control Charts for Individual Measurements*, Journal of Quality Technology, Vol. 14, No. 34, July 1982].
- [68] Altman, Rachel MacKay, *Introduction to Control Charts*, <http://people.stat.sfu.ca/~raltman/stat300/L15>].
- [69] Montgomery, D. (2001), *Introduction to statistical quality control*, 4th edition. John Wiley & Son],
- [70] Chiang, C.L, (2003) *Statistical methods of analysis*, World Scientific. ISBN 981-238-310-7].
- [71] M. H. Kutner, C. J. Nachtsheim, and J. Neter (2004), *Applied Linear Regression Models*, 4th ed., McGraw-Hill/Irwin, Boston].

- [72] Armstrong, J. Scott (2012) *Illusions in Regression Analysis*, *International Journal of Forecasting* 28].
- [73] David A. Freedman, *Statistical Models: Theory and Practice*, Cambridge University Press (2005)].
- [74] Good, P. I.; Hardin, J. W. (2009), *Common Errors in Statistics (And How to Avoid Them)*, (3rd ed.). Hoboken, New Jersey: Wiley. p. 211. [ISBN 978-0-470-45798-6](#)].
- [75] Chiang, C.L, (2003) *Statistical methods of analysis*, World Scientific. [ISBN 981-238-310-7](#) - [page 274](#).
- [76] Kenney, J. F. and Keeping, E. S. (1962) *Linear Regression and Correlation* Ch. 15 in *Mathematics of Statistics*, Pt. 1, 3rd ed. Princeton, NJ: Van Nostrand].
- [77] H.P. Ritzema (1994), *Frequency and Regression Analysis*, Drainage Principles and Applications, International Institute for Land Reclamation and Improvement (ILRI), Wageningen, The Netherlands. [ISBN 90-70754-33-9](#)].
- [78] Oakland, J. (2002), *Statistical Process Control*, [ISBN 0-7506-5766-9](#)].
- [79] Pyzdek, T, *Quality Engineering Handbook*, 2003, [ISBN 0-8247-4614-7](#)].
- [80] Bothe, D. R., *Measuring Process Capability*, 2001, [ISBN 0-07-006652-3](#)].
- [81] Booker, J. M.; Raines, M.; Swift, K. G. (2001), *Designing Capable and Reliable Products* Oxford: Butterworth-Heinemann, [ISBN 978-0-7506-5076-2](#). [OCLC 47030836](#)].
- [82] *What is Process Capability?*, [NIST/Sematech Engineering Statistics Handbook](#). National Institute of Standards and Technology, Retrieved 2008].
- [83] Wheeler, D, J. *The problem of Long Term Capability*, *Quality Digest*, 2013].

[84] Montgomery, Douglas (2004). *Introduction to Statistical Quality Control*. John Wiley & Sons, Inc. New York, p. 776. ISBN 978-0-471-65631-9. OCLC 56729567].

[85] Booker, J. M.; Raines, M.; Swift, K. G. (2001). *Designing Capable and Reliable Products*, Oxford: Butterworth-Heinemann, ISBN 978-0-7506-5076-2. OCLC 47030836].

[86] Boyles, Russell (1991), *The Taguchi Capability Index*, Journal of Quality Technology 23 (1) (American Society for Quality Control), ISSN 0022-4065].

[87] *What is Process Capability?*, NIST/Sematech Engineering Statistics Handbook. National Institute of Standards and Technology, 2008].

[87a] Lancaster, 1974] Lancaster, H.O.: *An Introduction to Medical Statistics*. John Wiley and Sons. 1974.

[88] Carleton, A (2001) *Statistical Process Control for Software*, Software Engineering Institute].

[89] Cleveland, William (1993), *Visualizing data*, Murray Hill, N.J. Summit, N.J: At & T Bell Laboratories Published by Hobart Press. ISBN 978-0963488404].

[90] Jarrell, Stephen B. (1994), *Basic Statistics*, Dubuque, Iowa: Wm. C. Brown Pub. p. 492. ISBN 0-697-21595-4].

[91] Slavek, N.: Osiguranje kvalitete programske podrške, ETFOS, Osijek 2016

[92] Juran, Joseph M. (1995), *A History of Managing for Quality: The Evolution, Trends, and Future Directions of Managing for Quality*, Milwaukee, Wisconsin: ASQC Quality Press, ISBN 9780873893411, OCLC 32394752].

[93] Hoyle, David (2007), *Quality Management Essentials*, Oxford, United Kingdom: Butterworth-Heinemann, ISBN 9780750667869].

[94] Aguayo, Rafael (1990), *Dr. Deming, The American Who Taught the Japanese About Quality*, Simon & Schuster.

[95] IEEE Spectrum 1993]. IEEE Spectrum. 1993. Special report: Manufacturing a la carte. Institute of Electrical and Electronic Engineers Spectrum 30(9):24-27.

[96] Taguchi, 1993] Taguchi, G. 1993. Robust Development. New York: American Society of Mechanical Engineers Press.

[97] 2 What are Unit Manufacturing Processes?." National Research Council. *Unit Manufacturing Processes: Issues and Opportunities in Research*. Washington, DC: The National Academies Press, 1995. doi:10.17226/4827.

[98] Clausing, D.P. 1994. Total Quality Engineering: A Step-by-Step Guide to World Class Concurrent Engineering. New York: American Society of Mechanical Engineers Press.

[99] NRC (National Research Council). 1988. The Technological Dimensions of International Competition. National Academy of Engineering, NRC. Washington, D.C.: National Academy Press.

[100] Bakerjian R., ed. 1993. Tool and Manufacturing Engineers Handbook. Volume 7, Continuous Improvement. Dearborn, Michigan: Society of Manufacturing Engineers.

[101] H. Charboneau, G. Webster, Industrial quality control, Prentice-Hall, Englewood Cliffs NJ, 1997.

[102] E.P. Paladini, An expert system approach to quality control, Expert Syst. Appl. 18 (2) (2000) 133–151.

[103] N.R. Tague, The Quality Toolbox, 2nd edition, American Society for Quality, Milwaukee WI, 2004.

[104] K. Ishikawa, Introduction to Quality Control, first ed., Productivity Press, New York, 1990.

[105] P.H. Tsarouhas, D. Arampatzaki, Application of Failure Modes and Effects Analysis (FMEA) of a Ceramic Tiles Manufacturing Plant, D. Aldonis, I. Manikas, D. Folinas (Eds.), Proc. 1st Int. Conf. on Supply Chains, Katerini, Greece, 2010, pp. 1–17.

[106] A.B. Yeh, D.K.K. Lin, H. Zhou, C. Venkataramani, A multivariate exponentially weighted moving average control chart for monitoring process variability, Journal of Applied Statistics 30 (5) (2003) 507–536.

[107] I.T. Cameron, G. D. Ingram, A survey of industrial process modeling across the product and process lifecycle, Computers& Chemical Engineering, Vol 32 Issue 3, 24 March 2008, pp 420-438 [doi:10.1016/j.compchemeng.2007.02.015](https://doi.org/10.1016/j.compchemeng.2007.02.015).

- [108] Y.C. Lee, L.C. Sheu, Y.G. Tsou, Quality function deployment implementation based on Fuzzy Kano model: An application in PLM system, *Comput. Ind. Eng.* 55 (1) (2008) 48–63.
- [109] C.-H. Chen, Y.-T. Chong, W. Chang, W. Yan, A quality–time–cost-oriented strategy for product conceptualization, *Advanced Engineering Informatics* 26 (2012) 16–25.
- [110] F. Jovic, *Expert Systems in Process Control*, Chapman & Hall, London, 1992.
- [111] Jovic, F., Jovic, A., & Krmpotic, D. (2013). Quality Control Engineering in Automated Ceramic Tile Production Using a Signal Information Content Approach. *Advanced Engineering Informatics*, 27(1), 93-107. doi:10.1016/j.aei.2012.11.007.
- [112] C.-H. Chen, Y.-T. Chong, W. Chang, W. Yan, A quality–time–cost-oriented strategy for product conceptualization, *Advanced Engineering Informatics* 26 (2012) 16–25.
- [113] Jean-Charles, Pomerol. Scenario development and practical decision making under uncertainty. *Decision Support Systems*; 31. 2001 197–204 www.elsevier.com/locate/dsw.
- [114] C. Kao, H.T. Hung, Management performance: an empirical study of the manufacturing companies in Taiwan, *Omega* 35 (2) (2007) 152–160.
- [115] B. Maskell, Performance measurement for world class manufacturing, *Manage. Account.* 67 (5) (1989) 32–33.
- [116] F.M. Tseng, Y.J. Chiu, J.S. Chen, Measuring business performance in the high-tech manufacturing industry: A case study of Taiwan’s large sized TFT-LCD panel companies, *Omega* 37 (3) (2009) 686–697.
- [117] T.L. Saaty, *The analytic hierarchy process*, McGraw-Hill, New York, 1980.
- [118] W.A. Tan, W. Shen, J. Zhao, A methodology for dynamic enterprise process performance evaluation, *Comput. Ind.* 58 (5) (2007) 474–485.
- [119] ISO 13006:1998: Ceramic tiles - Definitions, classification, characteristics and marking, International Organization for Standardization, Geneva, Switzerland, 1998. http://www.iso.org/iso/catalogue_detail.htm?csnumber=1732
- [120] S. Kukkonen, H. Kälviäinen, J. Parkkinen, Color features for quality control in ceramic tile industry, *Opt. Eng.* 40(2), 170-177 (Feb. 01,2001)doi:10.1117/1.1339877.
- [121] C. Chatfield, *The Analysis of Time Series: An Introduction*, 5th ed., Chapman & Hall, New York NY, 1996.
- [122] V.S. Lerner, Information System Theory and Informational Macrodynamics: Review of the Main Results, *IEEE T. Syst. Man Cy.* C 37 (6) (2007) 1050–1066.

- [123] S.M. Pincus, Approximate entropy as a measure of system complexity. *Proc. Natl. Acad. U. S. A.* 1991 Mar 16; 88(6); 2297-2301.
- [124] Jagnjić, Z., Bogunović, N., Pizeta, I., & Jović, F. (2009). Time series classification based On qualitative space segmentation. *Advanced Engineering Informatics*, 23(1), 116-129. doi: 10.1016/j.aei.2008.07.006.
- [125] Zenhausern F., Method and apparatus for monitoring materials used in electronics, United States Patent 6,975,944, December 13, 2005.
- [126] Jagnjić Ž., Ekspanzija ulaznog toka podataka razvijem vektora razlike sadržaja udesno s primjenom na kvalitativno modeliranje. DZIV Patent P20000500, 25.07.2000.
- [127] Taborsky E., Emotions as forms of consciousness, *Proceedings of the 1999 IEEE International Symposium on Intelligent Control, Intelligent Systems and Semiotics*, 15-17 Sept. 1999, Cambridge, USA, pp. 58-63.
- [128] Weidenhover I., Detailed angular correlation analysis with 4 pi spectrometers: Spin determinations and multipolarity mixing measurement in ^{128}Ba . *Physical Review C-Nuclear Physics* 58 (2) (1998), 721-728.
- [129] Robertson A. M., Willett, P., Applications of n-grams in textual information systems. *Journal of Documentation* 54 (1) (1998) 48-69.
- [130] Lawrence D., *Handbook of Genetic Algorithms*, Van Nostrand Reinhold Publishers: New York, USA, 1991.
- [131] Jović F., Qualitative Reasoning and a Circular Information Processing Algebra. *Informatica* 21 (1997), 31-47.
- [132] Jović F., A circular Qualitative Algebra. *CASYS: International journal of computing anticipatory systems* 8 (2001), 213-225.
- [133] Pavlić I. *Statistička teorija i primjena*. Tehnička knjiga, Zagreb, (1988).
- [134] A.V. Feigenbaum, *Total Quality Management*. Wiley On-line 2002, DOI: 10.1002/0471028959.sof359.
- [135] B.B. Flynn et al. Empirical research methods in operations management, *Journal of Operations Management* vol 9., issue 2, April 1990 , pp 250-284.
- [136] Buckley P.S. *Techniques of Process Control*. John Wiles & Sons, Inc. New York. 1964. p.102.
- [137] M. L. Smith, R. J. Stamp, *Automated inspection of textured ceramic tiles*. *Computers in Industry* 43 (2000) 73-82.

- [138] A. R. Farooq, M. L. Smith, L. N. Smith, S. Midha, *Dynamic photometric stereo for on line quality control of ceramic tiles*. Computers in Industry 56 (2005) 918-934.
- [139] S. Kukkonen, H. Kälviäinen, J. Parkkinen, Color features for quality control in ceramic tile industry, Opt. Eng. 40 (2001), 170–177.
- [140] I.T. Cameron, G. D. Ingram, A survey of industrial process modeling across the product and process lifecycle, Comput. Chem. Eng. 32 (3) (2008) 420–438.
- [141] H. Deng, G. Runger, E. Tuv, System monitoring with real-time contrasts, Journal of Quality Technology 44 (1) (2012) 9–27.
- [142] Biggs, D., Swailes, S. (2005.), Relations, commitment and satisfaction in agency workers and permanent workers. *Employee Relations*, Vol. 28 No. 2, 2006., pp. 130-143.
- [143] Hafeez, K., Essmail, E. (2007.), Evaluating organisation core competences and associated personal competencies using analytical hierarchy process. *Management Research News*, Vol. 30 No. 8, 2007., pp. 530-547.
- [144] Jackson, S. E., Joshi, A., Erhardt, N. L. (2003.), Recent Research on Team and Organizational Diversity: SWOT Analysis and Implications. *Journal of Management*, Volume 29, Issue 6, December 2003.
- [145] I.T. Cameron, G. D. Ingram, A survey of industrial process modeling across the product and process lifecycle, Comput. Chem. Eng. 32 (3) (2008) 420–438.
- [146] Peters, M., Zelewski, S. (2007.), Assignment of employees to workplaces under consideration of employee competences and preferences. *Management Research News*, Vol. 30 No. 2, 2007., pp. 84-99.
- [147] M. R. Beauregard, R. McDermott, M. Beauregard, The Basics of FMEA, second ed., Taylor & Francis Group LLC, New York, 2009.
- [148] G. Bosi, SACMI Imola Italija, Manager of the New Development Service for Automation and Inspection System, privatno priopćenje, 2016.
- [149] ISO 9000: 2015 Sustavi upravljanja kvalitetom
- [150] Mundfrom, D.J., Shaw, D.G., & Ke, T.L. (2005). Minimum sample size recommendations for conducting factor analyses. *International Journal of Testing*, 5 (2), 159-168.

Sažetak

Prikazan je postupak kojim se u potpuno automatiziranom i robotiziranom proizvodnom procesu određuju mjesta potencijalnog pada kvalitete izlaznog proizvoda u vremenu koje je i do reda veličine kraće od klasičnih statističkih postupaka kontrole kvalitete. Postupak je zasnovan na usporedbenoj analizi entropija procesnih signala kontrole kvalitete i signala škarta izlazne kvalitete obročnog proizvodnog procesa u keramičkoj industriji. Ovime se predlaže metodologija primjene razvijenog postupka za poboljšanje ekonomičnosti automatizirane proizvodnje u keramičkoj industriji uz smjensko praćenje procesnih signala kontrole kvalitete. Postupak određivanje entropije povezan je s jednodimenzijском Carnapovom entropijom kojom se procesni signali očitavaju u posmačnim četvorkama mjernog obrasca. Ovi se obrasci međutim moraju ekspandirati na sve moguće pozitivno vremenski usmjerene mjerne razlike svih četiriju procesnih mjerenja, kako bi se dobila jedinstvena procesna kodna i entropijska mjera obrasca, te tako omogućila detekcija mjesta greške u proizvodnom procesu s ciljem njegove korekcije.

Ključne riječi

Optimizacija proizvodnog procesa, sadržaj procesnih signala, teselacijska entropija, kontrola kvalitete, upravljanje kvalitetom.

Information Pattern Analysis of Process Signals by Expanded 1D Carnap Entropy

Summary

A procedure is described that determines positions of potential quality decrease of the output product in automatized and robotized production process with time delay that is at up to an order of magnitude shorter than classical statistical quality control procedures. The procedure is based on comparative analysis of entropies of process quality control signals and fallout signal of the quality control in batch process of the ceramic tile production. Thus a proposed application is obtained that is usable for the production economy increase while using quality control process signals based on shift data follow up. The procedure for determining entropy is connected to one-dimensional Carnap entropy concept based on process data sampling in shifted four sample frame. The collected patterns have to be expanded using all possible positive time directed measurement differences of all four process measurements in order to obtain a unique process coding and entropy of the patterns, thus enabling the detection of production process error with the aim of its correction.

Key words

Production process optimization, Process signals contents, Tessellation entropy, Quality control, Quality management.

ŽIVOTOPIS

Darko Krmpotić (rođen 12.08.1959 u Orahovici), završio je srednju građevinsku školu u Zagrebu 1979. godine, diplomirao na Građevinskom fakultetu Sveučilišta u Zagrebu 1985. godine i magistrirao na Elektrotehničkom fakultetu Sveučilišta J.J. Strossmayera u Osijeku 2005. godine. Radio je kao privremeni upravitelj i pomoćnik direktora firme Radlovac u Orahovici 1987-1991 godine. Bio je stečajni upravitelj firme Čelik d.d. u Orahovici 1991-1995., te direktor poduzeća KIO Keramika d.o.o. u Orahovici 1994-2010.

Od upisa poslijediplomskog studija 2002. godine objavio je četiri rada na skupovima s međunarodnom recenzijom na temu primjene teorije sivih sustava u poboljšanju energetike proizvodnog procesa te na istraživanju mogućnosti otkrivanja greški u automatiziranim industrijskim postrojenjima. Objavio je i četiri znanstvena članka na temu kvalitete softvera, istraživanja u kontroli kvalitete pri proizvodnji keramičkih pločica s naglaskom na specifičnost industrijske proizvodnje u Hrvatskoj u uvjetima visoke automatiziranosti i robotiziranosti pogona. Godine 2014 upisao je poslijediplomski doktorski studij pri Elektrotehničkom fakultetu Sveučilišta J.J. Strossmayera u Osijeku.

Služi se ruskim i engleskim jezikom.

Odlikovan je 2005. godine ordenom reda Danice s likom Blaža Lorkovića od strane Predsjednika RH, dok je 2004. godine proglašen menadžerom godine od hrvatske udruge CROMA.

U braku je sa mr.sc. Dubravkom Slavić-Krmpotić, doktoricom dentalne medicine, od 1987. godine. Otac je dviju kćeri.

Član je "Lions" kluba Našice. Član je družbe "Braća hrvatskog zmaja".

Dodaci A,B,C, D**Dodatak A**

Pregled mjernih vrijednosti procesnih signala kvalitete i signala izlazne kvalitete za razdoblje kolovoza i rujna 2008. godine.

	QA signal		BROJ	VLAGA	TEMPERATURA			
DATUM	ukupno +1	signal 48	signal 49	signal 50	signal 51	signal 44	signal 45	signal 46
7.8.2008	4,29	1121	1128	1121	1121	1160	1135	1160
8.8.2008	2,62	1123	1128	1123	1123	1160	1143	1160
8.8.2008	2,62	1123	1128	1123	1123	1160	1143	1160
8.8.2008	2,62	1123	1128	1123	1123	1160	1143	1160
9.8.2008	1,62	1123	1128	1123	1123	1153	1142	1153
9.8.2008	1,62	1123	1128	1123	1123	1153	1142	1153
10.8.2008	2,72	1126	1126	1126	1126	1153	1142	1153
10.8.2008	2,72	1126	1126	1126	1126	1153	1142	1153
10.8.2008	2,72	1126	1126	1126	1126	1153	1142	1153
11.8.2008	3,79	1120	1122	1120	1120	1151	1138	1151
11.8.2008	3,79	1120	1122	1120	1120	1151	1138	1151
12.8.2008	3,38	1118	1125	1118	1118	1151	1138	1151
12.8.2008	3,38	1118	1125	1118	1118	1151	1138	1151
13.8.2008	2,73	1116	1123	1116	1116	1151	1138	1151
13.8.2008	2,73	1116	1123	1116	1116	1151	1138	1151
14.8.2008	3,63	1116	1123	1116	1116	1151	1137	1151
14.8.2008	3,63	1116	1123	1116	1116	1151	1137	1151
16.8.2008	5,89	1116	1123	1116	1116	1151	1137	1151
17.8.2008	2,01	1123	1130	1123	1123	1154	1136	1154

18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162
18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162
18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162
19.8.2008	2,58	1130	1130	1130	1130	1160	1145	1160
20.8.2008	0,71	1132	1132	1132	1132	1165	1145	1165
21.8.2008	3,95	1132	1132	1132	1132	1162	1148	1162
21.8.2008	3,95	1132	1132	1132	1132	1162	1148	1162
22.8.2008	1,28	1130	1136	1130	1130	1162	1148	1162
23.8.2008	3,23	1129	1135	1120	1135	1162	1148	1162
23.8.2008	3,23	1129	1135	1120	1135	1162	1148	1162
24.8.2008	7,41	1129	1135	1129	1135	1162	1148	1162
25.8.2008	4,12	1118	1132	1118	1132	1165	1150	1165
25.8.2008	4,12	1118	1132	1118	1132	1165	1150	1165
26.8.2008	6,03	1118	1132	1118	1132	1165	1150	1165
27.8.2008	2,5	1118	1132	1118	1132	1160	1145	1160
28.8.2008	0,88	1120	1130	1120	1130	1160	1145	1160
29.8.2008	5,57	1120	1130	1120	1130	1160	1145	1160
29.8.2008	5,57	1120	1130	1120	1130	1160	1145	1160
31.8.2008	3,13	1120	1130	1120	1130	1160	1145	1160
1.9.2008	6,17	1118	1132	1118	1132	1162	1147	1162
1.9.2008	6,17	1118	1132	1118	1132	1162	1147	1162
1.9.2008	6,17	1118	1132	1118	1132	1162	1147	1162
2.9.2008	2,92	1118	1132	1118	1132	1162	1147	1162
2.9.2008	2,92	1118	1132	1118	1132	1162	1147	1162
3.9.2008	2,65	1118	1132	1118	1132	1162	1147	1162
3.9.2008	2,65	1118	1132	1118	1132	1162	1147	1162
4.9.2008	2,3	1118	1132	1118	1132	1162	1147	1162
4.9.2008	2,3	1118	1132	1118	1132	1162	1147	1162

Pritisak	DEBLJINA IZMEĐU REBARA - BROJ IZLAZA	BROJ	VLAGA	TEMPERATURA				Pritisak
signal 47	SMJENA	PREŠE	signal 10	signal 11	signal 12	signal 13	signal 14	signal 15
1135	III	9	6,1	44	45	50	42	270/270
1143	I	9	5,9	43	47	50	40	270/270
1143	II	9	5,8	45	44	51	46	270/270
1143	III	9	5,8	45	44	52	39	270/270
1142	I	9	5,6	45	45	50	38	270/270
1142	III	9	5,9	44	46	49	39	270/270
1142	I	9	5,6	45	44	50	38	270/270
1142	II	9	5,6	42	45	59	41	270/270
1142	III	9	5,8	43	44	48	40	270/270
1138	I	9	5,9	47	47	49	35	270/270
1138	III	9	5,8	46	47	49	35	270/270
1138	I	9	5,9	47	46	51	40	270/270
1138	III	9	5,8	47	47	52	40	270/270
1138	I	9	5,9	45	46	49	38	270/270
1138	II	9	5,4	47	44	51	45	270/270
1137	I	9	5,7	46	46	50	39	270/270
1137	II	9	5,8	46	48	49	42	270/270
1137	III	9	5,6	49	44	50	36	270/270
1136	II	9	5,7	42	47	49	38	270/270
1144	I	9	5,9	47	46	51	41	270/270
1144	II	9	5,8	43	45	51	41	270/270
1144	III	9	5,4	45	44	51	31	270/270
1145	I	9	5,7	43	45	52	38	270/270
1145	I	9	5,8	44	45	51	44	270/270
1148	I	9	5,7	44	46	51	44	270/270

1148	II	9	5,8	47	46	50	45	270/270
1148	I	9	5,6	45	45	49	43	270/270
1148	II	9	5,5	47	44	50	46	270/270
1148	III	9	5,5	47	46	50	49	270/270
1148	II	9	5,6	47	45	50	44	270/270
1150	I	9	5,8	41	45	52	34	270/270
1150	III	9	5,8	43	44	51	41	270/270
1150	I	9	5,7	42	45	51	41	270/270
1145	I	9	5,8	43	41	51	42	270/270
1145	I	9	5,9	43	44	50	44	270/270
1145	I	9	5,9	45	44	49	37	270/270
1145	II	9	5,9	45	44	49	46	260/260
1145	III	9	5,5	44	41	51	40	260/260
1147	I	9	5,8	40	46	55	41	260/260
1147	II	9	5,6	42	44	50	42	
1147	III	9	5	42	44	49	46	
1147	I	9	4,7	41	46	50	43	
1147	III	9	4,9	45	44	52	44	
1147	II	9	5,4	46	46	50	42	
1147	III	9	5,4	46	44	49	45	
1147	I	9	4,7	45	44	50	46	
1147	III	9	5,4	48	45	52	42	

DEBLJINA IZMEĐU REBARA - BROJ IZLAZA					DEBLJINA PREKO REBARA - BROJ IZLAZA			
signal 16	signal 17	signal 18	signal 19	signal 20	signal 21	signal 22	signal 23	signal 24
7	7,2	7,1	7,2	7,3	7,3	7,3	7,2	7,3
7	7,2	7,1	7,2	7,3	7,3	7,6	7,6	7,6
7	7,1	7,1	7,2	7,3	7,3	7,3	7,3	7,3
7	7,1	7,1	7,2	7,3	7,5	7,5	7,5	7,5
7,1	7,1	7,1	7,2	7,2	7,4	7,3	7,3	7,3
7,1	7,1	7,1	7,2	7,2	7,4	7,4	7,4	7,5
7,1	7,1	7	7,1	7,2	7,5	7,5	7,3	7,4
7,1	7,1	7	7,1	7,2	7,4	7,4	7,3	7,4
7,1	7,1	7	7,1	7,2	7,3	7,3	7,3	7,4
7,1	7,2	7,1	7,2	7,4	7,5	7,5	7,5	7,6
7,1	7,2	7,1	7,2	7,4	7,5	7,6	7,4	7,5
7,1	7,1	7,1	7,1	7,1	7,4	7,4	7,4	7,4
7,1	7,1	7,1	7,1	7,1	7,4	7,4	7,4	7,5
7,2	7,2	7,2	7,2	7,3	7,5	7,6	7,6	7,7
7,2	7,2	7,2	7,2	7,3	7,4	7,5	7,6	7,7
7,2	7,1	7,2	7,3	7,4	7,6	7,6	7,6	7,7
7,2	7,1	7,2	7,3	7,4	7,4	7,4	7,4	7,5
7,2	7,1	7,2	7,3	7,4	7,3	7,3	7,3	7,4
7,2	7,1	7,2	7,3	7,4	7,5	7,4	7,4	7,5
7,2	7,1	7,1	7,1	7	7,5	7,5	7,4	7,4
7,2	7,1	7,1	7,1	7	7,4	7,4	7,4	7,4
7,2	7,1	7,1	7,1	7	7,5	7,5	7,5	7,6
7,2	7,1	7,1	7,2	7,3	7,5	7,5	7,5	7,5
7	7,1	7	7,1	7,1	7,5	7,5	7,5	7,5

7,1	7,1	7,1	7,2	7,2	7,5	7,5	7,5	7,6
7,1	7,1	7,1	7,2	7,2	7,4	7,4	7,5	7,4
7,1	7,1	7,1	7,1	7,3	7,4	7,4	7,4	7,5
7,1	7,1	7,1	7,1	7,3	7,6	7,6	7,5	7,6
7,1	7,1	7,1	7,1	7,3	7,5	7,5	7,4	7,4
7,1	7,1	7,1	7,1	7,3	7,5	7,5	7,5	7,5
7,2	7,2	7,3	7,3	7,3	7,7	7,7	7,5	7,6
7,2	7,2	7,3	7,3	7,3	7,4	7,4	7,5	7,5
7,2	7,1	7	7,2	7,2	7,3	7,3	7,4	7,5
7,2	7,2	7,2	7,3	7,3	7,6	7,6	7,6	7,6
7,2	7,2	7,3	7,3	7,4	7,8	7,7	7,7	7,7
7,2	7,1	7,1	7,2	7,3	7,5	7,4	7,4	7,5
7,2	7,1	7,1	7,2	7,3	7,5	7,5	7,4	7,5
7,2	7,1	7,1	7,2	7,3	7,1	7,1	7,2	7,2
7,1	7,1	7,1	7,2	7,3	7,5	7,5	7,5	7,6
7.sij	7,1	7,1	7,2	7,3	7,6	7,6	7,6	7,7
7,1	7,1	7,1	7,2	7,3	7,5	7,5	7,6	7,6
7,1	7,1	7	7,1	7,2	7,5	7,4	7,4	7,4
7,1	7,1	7	7,1	7,2	7,4	7,5	7,6	7,6
7,1	7,1	7	7,1	7,2	7,3	7,3	7,4	7,4
7,1	7,1	7	7,1	7,2	7,5	7,5	7,4	7,5
7,2	7,2	7,2	7,3	7,4	7,5	7,6	7,6	7,7
7,2	7,2	7,2	7,3	7,4	7,3	7,3	7,3	7,3

	KLINAVOST IZMEĐU REBARA - BROJ IZLAZA					KLINAVOST PREKO REBARA - BROJ IZLAZA		
signal 25	signal 26	signal 27	signal 28	signal 29	signal 30	signal 31	signal 32	signal 33
7,4	0,2	0,1	0,1	0,1	0,1	0,1	0,2	0,2
7,7	0,2	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,5	0,2	0,1	0,1	0,1	0,1	0,3	0,3	0,3
7,5	0,2	0,1	0,1	0,1	0,1	0,2	0,2	0,1
7,4	0,1	0,1	0,2	0,2	0,1	0,2	0,2	0,1
7,5	0,1	0,1	0,2	0,2	0,1	0,2	0,2	0,2
7,5	0,1	0,1	0,2	0,2	0,2	0,2	0,2	0,1
7,4	0,1	0,1	0,2	0,2	0,2	0,2	0,1	0,2
7,4	0,1	0,1	0,2	0,2	0,2	0,2	0,3	0,2
7,7	0,1	0,1	0,2	0	0	0,2	0,2	0,2
7,6	0,1	0,1	0,2	0	0	0,2	0,2	0,2
7,5	0,1	0,1	0,1	0	0,1	0,2	0,2	0,2
7,6	0,1	0,1	0,1	0	0,1	0,2	0,2	0,2
7,7	0,1	0,1	0,1	0,1	0,2	0,2	0,3	0,2
7,6	0,1	0,1	0,1	0,1	0,2	0,1	0,1	0,1
7,7	0,1	0,2	0,1	0,1	0,1	0,2	0,2	0,2
7,5	0,1	0,2	0,1	0,1	0,1	0,2	0,2	0,2
7,5	0,1	0,2	0,1	0,1	0,1	0,3	0,2	0,2
7,5	0,1	0,2	0,1	0,1	0,1	0,2	0,2	0,2
7,4	0,1	0	0,1	0,1	0,1	0,2	0,2	0,2
7,5	0,1	0	0,1	0,1	0,1	0,3	0,2	0,2
7,6	0,1	0	0,1	0,1	0,1	0,2	0,1	0,2
7,6	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,3

7,6	0,2	0,1	0,2	0,2	0,2	0,3	0,2	0,3
7,6	0,2	0,2	0,2	0,2	0,2	0,3	0,3	0,3
7,6	0,2	0,2	0,2	0,2	0,2	0,3	0,3	0,2
7,5	0,1	0,1	0,1	0	0,1	0,2	0,2	0,2
7,6	0,1	0,1	0,1	0	0,1	0,2	0,2	0,2
7,5	0,1	0,1	0,1	0	0,1	0,2	0,2	0,2
7,6	0,1	0,1	0,1	0	0,1	0,3	0,3	0,3
7,6	0,1	0,1	0,1	0,1	0	0,3	0,3	0,2
7,5	0,1	0,1	0,1	0,1	0	0,2	0,2	0,2
7,6	0,1	0,1	0	0,1	0,1	0,3	0,2	0,2
7,6	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,7	0,2	0	0,1	0,1	0,1	0,3	0,2	0,3
7,6	0,1	0	0	0,1	0,1	0,3	0,2	0,2
7,5	0,1	0	0	0,1	0,1	0,3	0,2	0,2
7,2	0,1	0	0	0,1	0,1	0,1	0,1	0,1
7,6	0,1	0,1	0	0,1	0,1	0,2	0,2	0,1
7,7	0,1	0,1	0	0,1	0,1	0,1	0,1	0,2
7,7	0,1	0,1	0	0,1	0,1	0,3	0,2	0,1
7,5	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,5	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,4	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,6	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,9	0,1	0	0,1	0,1	0,1	0,2	0,2	0,2
7,4	0,1	0	0,1	0,1	0,1	0,1	0,1	0,1

		ČVRSTOĆA - BROJ IZLAZA				
signal 34	signal 35	signal 36	signal 37	signal 38	signal 39	signal 40
0,2	0,2	0,9	0,9	0,7	0,9	1
0,2	0,2	0,9	0,9	0,7	0,9	1
0,2	0,2	0,9	0,9	0,7	0,9	1
0,2	0,2	0,9	0,9	0,7	0,9	1
0,1	0,1	0,9	1	1	1,2	0,9
0,2	0,2	0,9	1	1	1,2	0,9
0,2	0,2	1	1	0,9	1,2	0,9
0,2	0,2	1	1	0,9	1,2	0,9
0,2	0,3	1	1	0,9	1,2	0,9
0,3	0,2	1	0,9	1	0,8	1,1
0,2	0,3	1	0,9	1	0,8	1,1
0,2	0,2	1	0,7	0,9	0,8	0,8
0,2	0,2	1	0,7	0,9	0,8	0,8
0,3	0,2	0,7	0,9	0,9	0,9	0,9
0,1	0,3	0,7	0,9	0,9	0,9	0,9
0,2	0,2	0,9	1,1	1,1	0,9	1,1
0,2	0,2	0,9	1,1	1,1	0,9	1,1
0,2	0,1	0,9	1,1	1,1	0,9	1,1
0,2	0,2	0,9	1,1	1,1	0,9	1,1
0,2	0,2	0,7	0,8	0,7	0,8	0,8
0,2	0,2	0,7	0,8	0,7	0,8	0,8
0,2	0,2	0,7	0,8	0,7	0,8	0,8
0,2	0,2	0,8	0,8	0,9	0,7	0,9
0,2	0,3	0,8	0,9	0,9	0,9	0,8

0,2	0,2	0,7	0,8	0,7	0,8	0,8
0,2	0,1	0,7	0,8	0,8	0,8	0,8
0,2	0,3	0,7	0,7	0,8	0,8	0,9
0,2	0,2	0,7	0,7	0,8	0,8	0,9
0,2	0,3	0,7	0,7	0,8	0,8	0,9
0,2	0,2	0,7	0,7	0,8	0,8	0,9
0,3	0,2	0,8	0,8	0,8	0,7	0,8
0,2	0,2	0,8	0,8	0,8	0,7	0,8
0,3	0,3	0,8	0,7	0,8	0,8	0,7
0,3	0,3	0,8	0,7	1	0,8	0,9
0,2	0,2	0,9	0,9	0,9	0,7	0,8
0,2	0,1	0,7	0,7	0,8	0,8	0,6
0,2	0,2	0,7	0,7	0,8	0,8	0,6
0,1	0	0,7	0,7	0,8	0,8	0,6
0,1	0,2	0,9	0,9	1	0,9	0,7
0,1	0,1	0,9	0,9	1	0,9	0,7
0,2	0,3	0,9	0,9	1	0,9	0,7
0,2	0,1	0,6	0,6	0,7	0,6	0,7
0,2	0,1	0,6	0,6	0,7	0,6	0,7
0,2	0,2	0,6	0,6	0,7	0,6	0,7
0,2	0,2	0,6	0,6	0,7	0,6	0,7
0,2	0,1	0,8	0,8	0,7	0,8	0,8
0,2	0,2	0,8	0,8	0,7	0,8	0,8

	QA signal		BROJ	VLAGA	TEMPERATURA			
DATUM	ukupno +1	signal 48	signal 49	signal 50	signal 51	signal 44	signal 45	signal 46
6.9.2008	3,54	1122	1132	1122	1132	1167	1147	1166
7.9.2008	4,66	1122	1132	1122	1132	1167	1147	1166
7.9.2008	4,66	1122	1132	1122	1132	1167	1147	1166
8.9.2008	3,07	1122	1132	1122	1132	1167	1147	1166
8.9.2008	3,07	1122	1132	1122	1132	1167	1147	1166
8.9.2008	3,07	1122	1132	1122	1132	1167	1147	1166
9.9.2008	5,64	1122	1136	1122	1136	1169	1149	1169
9.9.2008	5,64	1122	1136	1122	1136	1169	1149	1169
9.9.2008	5,64	1122	1136	1122	1136	1169	1149	1169
10.9.2008	1,82	1120	1136	1122	1136	1168	1148	1168
10.9.2008	1,82	1120	1136	1122	1136	1168	1148	1168
13.8.2008	1,82	1116	1123	1116	1116	1151	1138	1151
13.8.2008	1,82	1116	1123	1116	1116	1151	1138	1151
14.8.2008	3,63	1116	1123	1116	1116	1151	1137	1151
14.8.2008	3,63	1116	1123	1116	1116	1151	1137	1151
15.8.2008	1,31	1116	1123	1116	1116	1151	1137	1151
16.8.2008	5,89	1116	1123	1116	1116	1151	1137	1151
17.8.2008	2,01	1123	1130	1123	1123	1154	1136	1154
18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162
18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162
18.8.2008	1,69	1128	1133	1128	1128	1162	1144	1162

19.8.2008	2,58	1130	1130	1130	1130	1160	1145	1160
20.8.2008	0,71	1132	1132	1132	1132	1165	1145	1165
21.8.2008	3,95	1132	1132	1132	1132	1162	1148	1162
21.8.2008	3,95	1132	1132	1132	1132	1162	1148	1162
23.8.2008	3,23	1129	1135	1120	1135	1162	1148	1162
23.8.2008	3,23	1129	1135	1120	1135	1162	1148	1162
23.8.2008	3,23	1129	1135	1120	1135	1162	1148	1162
24.8.2008	7,41	1129	1135	1129	1135	1162	1148	1162
24.8.2008	7,41	1129	1135	1129	1135	1162	1148	1162
25.8.2008	4,12	1118	1132	1118	1132	1165	1150	1165
25.8.2008	4,12	1118	1132	1118	1132	1165	1150	1165
26.8.2008	6,03	1118	1132	1118	1132	1165	1150	1165
27.8.2008	2,5	1118	1132	1118	1132	1160	1145	1160
28.8.2008	0,88	1120	1130	1120	1130	1160	1145	1160
29.8.2008	5,57	1120	1130	1120	1130	1160	1145	1160
29.8.2008	5,57	1120	1130	1120	1130	1160	1145	1160
31.8.2008	3,13	1120	1130	1120	1130	1160	1145	1160
1.9.2008	6,17	1118	1132	1118	1132	1162	1147	1162
1.9.2008	6,17	1118	1132	1118	1132	1162	1147	1162

Pritisak	DEBLJINA IZMEĐU REBARA - BROJ IZLAZA	BROJ	VLAGA	TEMPERATURA				Pritisak
				signal 11	signal 12	signal 13	signal 14	
signal 47	SMJENA	PREŠE	signal 10	signal 11	signal 12	signal 13	signal 14	signal 15
1145	II	9	5,5	48	46	52	49	
1145	I	9	5,4	48	47	51	47	
1145	II	9	5,4	48	44	50	44	
1145	I	9	5,6	46	46	51	45	
1145	II	9	5,3	46	45	49	46	
1145	III	9	5,6	45	45	52	44	
1149	I	9	5,6	44	47	50	42	
1149	II	9	4,9	45	46	51	46	
1149	III	9	5,6	46	45	50	44	
1148	I	9	5,7	43	46	49	43	
1148	II	9	5,6	43	46	49	43	
1138	I	10	5,7	42	47	45	33	130/130
1138	II	10	5,6	40	46	46	39	130/130
1137	I	10	5,6	40	47	44	37	130/130
1137	II	10	5,8	40	47	47	39	130/130
1137	I	10	5,7	39	46	45	38	130/130
1137	III	10	5,5	41	48	45	33	130/130
1136	I	10	5,7	40	45	46	32	130/130
1144	I	10	5,6	44	44	44	32	130/130

1144	II	10	5,9	46	44	44	37	130/130
1144	III	10	5,5	47	49	47	33	130/130
1145	I	10	5,6	46	45	44	31	130/130
1145	I	10	5,7	44	46	46	35	130/130
1148	I	10	5,7	46	45	44	33	130/130
1148	II	10	5,4	47	48	45	34	130/130
1148	I	10	5,6	47	48	46	34	130/130
1148	II	10	5,7	45	48	45	38	130/130
1148	II	10	5,5	48	46	44	31	130/130
1148	I	10	5,6	44	45	46	36	130/130
1148	II	10	5,6	47	48	46	34	130/130
1150	I	10	5,7	47	44	46	31	130/130
1150	III	10	5,8	46	44	44	33	130/130
1150	I	10	5,6	47	47	45	35	130/130
1145	I	10	5,6	46	46	46	34	130/130
1145	I	10	5,8	47	46	46	34	130/130
1145	I	10	5,9	46	45	46	36	130/130
1145	II	10	5,6	48	45	46	38	130/130
1145	II	10	5,4	48	44	46	33	130/130
1147	I	10	5,6	44	44	46	30	130/130
1147	II	10	5,6	45	52	46	29	140/140

DEBLJINA IZMEĐU REBARA BROJ IZLAZA					DEBLJINA PREKO REBARA BROJ IZLAZA			
signal 16	signal 17	signal 18	signal 19	signal 20	signal 21	signal 22	signal 23	signal 24
7,1	7,1	7	7,1	6,9	7,5	7,5	7,4	7,5
7,1	7,1	7,1	7	7	7,5	7,5	7,4	7,4
7,1	7,1	7,1	7	7	7,2	7,2	7,2	7,3
6,9	7	6,9	7,9	7	7,3	7,3	7,3	7,4
7	7	6,9	6,9	6,9	7,6	7,5	7,4	7,4
7	7	6,9	6,9	6,9	7,3	7,3	7,3	7,4
7,2	7,2	7,2	6,9	7,2	7,7	7,7	7,6	7,4
7,2	7,2	7,2	6,9	7,2	7,6	7,5	7,5	7,4
7,2	7,2	7,2	6,9	7,2	7,3	7,3	7,3	7,4
6,8	6,9	6,9	6,9	7,1	7,3	7,3	7,3	7,4
6,8	6,9	6,9	6,9	7,1	7,3	7,3	7,3	7,4
6,9	6,8	6,8	6,9	6,8	7,4	7,4	7,4	7,4
6,9	6,8	6,8	6,9	6,8	7,3	7,3	7,3	7,3
6,7	6,6	6,6	6,7	6,7	7,3	7,2	7,2	7,3
6,7	6,6	6,6	6,7	6,7	7,1	7,1	7,1	7,1
6,4	6,4	6,4	6,5	6,5	7	7	7	7
6,4	6,4	6,4	6,5	6,5	7	7	7,1	7,1
6,4	6,4	6,4	6,5	6,5	7,1	7,1	7,1	7,1
6,4	6,5	6,6	6,4	6,5	7,1	7,1	7,1	7,2
6,4	6,5	6,6	6,4	6,5	7	7	7	7
6,4	6,5	6,6	6,4	6,5	7,2	7,2	7,2	7,1
6,5	6,4	6,4	6,4	6,4	7,1	7,1	7,1	7
6,5	6,5	6,4	6,4	6,4	7,1	7,1	7	7,1
6,7	6,6	6,6	6,6	6,7	7	7	7	7

6,7	6,6	6,6	6,6	6,7	7	6,9	7	7
6,6	6,7	6,7	6,7	6,6	7,2	7,3	7,3	7,3
6,6	6,7	6,7	6,7	6,6	7	7	7	7,1
6,6	6,7	6,7	6,76	6,6	7,2	7,2	7,2	7,2
6,4	6,4	6,4	6,9	6,5	7,2	7,1	7,1	7,2
6,4	6,4	6,4	6,9	6,5	7	7	7,1	7,1
6,5	6,5	6,5	6,6	6,7	7,2	7,2	7,2	7,2
6,5	6,5	6,5	6,6	6,7	6,9	7	7	7,1
6,4	6,4	6,5	6,6	6,6	7,1	7,1	7,1	7,2
6,4	6,4	6,5	6,6	6,6	7,1	7	7,1	7,2
6,6	6,5	6,6	6,6	6,6	7,2	7,1	7,1	7,2
6,4	6,4	6,4	6,5	6,5	7,1	7,1	7,1	7,2
6,4	6,4	6,4	6,5	6,5	6,9	6,9	6,9	7
6,4	6,4	6,4	6,5	6,5	7,4	7,4	7,4	7,5
6,8	6,8	6,7	6,6	6,6	7,4	7,3	7,3	7,2
6,8	6,8	6,7	6,6	6,6	7,2	7,3	7,3	7,3

	KLINAVOST IZMEĐU REBARA - BROJ IZLAZA					KLINAVOST PREKO REBARA - BROJ IZLAZA		
signal 25	signal 26	signal 27	signal 28	signal 29	signal 30	signal 31	signal 32	signal 33
7,5	0,1	0,1	0,2	0,1	0,1	0,1	0,1	0,1
7,4	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
7,4	0,1	0,1	0,1	0,1	0,1	0,1	0,2	0,1
7,4	0,1	0,1	0,2	0,1	0,1	0,1	0,1	0,1
7,4	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
7,4	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,6	0,1	0	0,1	0,1	0,1	0,2	0,2	0,2
7,8	0,1	0	0,1	0,1	0,1	0,1	0,2	0,2
7,5	0,1	0	0,1	0,1	0,1	0,1	0,2	0
7,5	0,1	0,1	0,1	0	0,1	0,1	0,1	0,1
7,5	0,1	0,1	0,1	0	0,1	0,1	0,1	0,1
7,4	0,2	0,1	0,1	0,1	0	0,1	0,1	0,2
7,3	0,2	0,1	0,1	0,1	0	0,2	0,2	0,1
7,3	0,1	0,2	0,2	0,2	0,2	0,1	0,2	0,2
7,1	0,1	0,2	0,2	0,2	0,2	0,2	0,2	0,2
7,1	0,1	0,2	0,1	0,2	0,1	0,2	0,2	0,2
7	0,1	0,2	0,1	0,2	0,1	0,2	0,2	0,1
7,1	0,1	0,2	0,1	0,2	0,1	0,1	0,2	0,2
7,2	0,1	0,1	0,1	0,2	0,1	0	0,1	0,1
7	0,1	0,1	0,1	0,2	0,1	0,2	0,1	0,1
7,1	0,1	0,1	0,1	0,2	0,1	0,1	0,1	0,1

7	0,1	0	0	0,1	0,1	0,1	0,1	0,1
7	0	0,1	0,1	0	0	0,1	0,1	0,1
7	0	0	0,1	0	0,1	0,1	0,1	0,1
7	0	0	0,1	0	0,1	0,1	0,1	0,2
7,2	0,1	0,1	0,1	0,1	0,1	0,1	0,2	0,2
7,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
7,2	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,2
7,2	0,1	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1	0,1
7,3	0,1	0	0	0	0,1	0,2	0,1	0,1
7,1	0,1	0	0	0	0,1	0,2	0,2	0,2
7,2	0	0,1	0,1	0,1	0,1	0,1	0,1	0,1
7,2	0,1	0,1	0,1	0	0	0,1	0,2	0,2
7,2	0,1	0,2	0,1	0,1	0	0,1	0,2	0,2
7,2	0	0,1	0,1	0,1	0,1	0,1	0,1	0,1
6,9	0	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,6	0	0,1	0,1	0,1	0,1	0,2	0,2	0,2
7,2	0,1	0,1	0,1	0,2	0,1	0,1	0,1	0,1
7,4	0,1	0,1	0,1	0,2	0,1	0,1	0,1	0,2

		ČVRSTOĆA - BROJ IZLAZA				
signal 34	signal 35	signal 36	signal 37	signal 38	signal 39	signal 40
0,2	0,2	0,8	0,7	0,8	0,8	0,8
0,2	0,2	0,7	0,7	0,7	0,8	0,8
0,1	0,2	0,7	0,7	0,7	0,8	0,8
0,1	0	0,8	0,7	0,9	0,8	0,8
0,1	0,1	0,8	0,7	0,9	0,6	0,9
0,1	0,1	0,8	0,7	0,9	0,6	0,9
0,1	0,2	1	0,8	0,9	0,6	0,7
0,1	0,2	1	0,8	0,9	0,6	0,7
0,2	0,1	1	0,8	0,9	0,6	0,7
0,1	0,1	0,8	0,7	0,7	0,7	0,7
0,1	0,1	0,8	0,7	0,7	0,7	0,7
0,1	0,1	1	0,7	0,6	1	1,3
0,1	0	1	0,7	0,6	1	1,3
0,1	0	1,2	0,8	0,6	1	1,4
0,2	0,2	1,2	0,8	0,6	1	1,4
0,2	0,1	1,1	1	0,9	1,1	1,3
0,1	0,1	1,1	1	0,9	1,1	1,3
0,2	0,2	1,1	1	0,9	1,1	1,3
0,2	0,2	1	0,7	0,8	0,9	1,3
0,2	0,2	1	0,7	0,8	0,9	1,3
0,1	0,1	1	0,7	0,8	0,9	1,3
0	0	1,2	1	1,4	1,4	1,5
0,1	0,1	1,4	1,2	0,8	1	1,3
0,1	0,1	1,2	1,2	1	1	1,4

0,1	0,1	1,2	1,2	1	1	1,4
0,2	0,2	1,1	0,8	1	1,1	1,2
0,1	0,1	1,1	0,8	1	1,1	1,2
0,1	0,2	1,1	0,8	1	1,1	1,2
0,2	0,2	1,1	1	0,8	0,8	1,1
0,2	0,2	1,1	1	0,8	0,8	1,1
0,2	0,1	0,8	0,7	1	1,1	1,3
0,2	0,2	0,8	0,7	1	1,1	1,3
0,1	0,1	1,1	1	0,8	1,1	1,5
0,1	0,1	1	0,8	0,6	1	1,2
0,1	0,1	1	0,8	1,1	1,1	1
0,1	0,1	0,8	1	0,8	1	1,1
0,1	0,2	0,8	1	0,8	1	1,1
0,1	0,1	0,8	1	0,8	1	1,1
0,2	0,2	0,8	0,8	1	0,9	1,1
0,1	0,1	0,8	0,8	1	0,9	1,1

Dodatak B

Pregled proizvodnje i kontrole kvalitete u KIO Orahovica

KIO Keramika d.o.o. bavi se proizvodnjom keramičkih pločica od 1981. godine. Proizvodnja suho prešanih i ekstrudiranih pločica za vanjska i unutrašnja oblaganja u KIO Keramici d.o.o. odvija se na dvije lokacije u Orahovici i Rujevcu. Na lokaciji u Orahovici osnovni proizvod je suho prešana keramička pločica za unutarnja oblaganja zida i poda proizvedena tehnologijom monopoljenja. Godišnja proizvodnja ovog pogona je 4,400.000 m² pločica. Tehnologijom trećeg paljenja omogućeno je oplemenjivanje gotove pločice unikatnim motivima i ukrašavanje modernim dizajnom te izrade bordura.


Tvornica ekstrudirane keramike počela je proizvodnjom 2004. godine s kapacitetom od 900.000 m² pločica. To su pločice izuzetne po svojim tehničko tehnološkim značajkama posebno otporne na smrzavanje. KIO Keramika d.o.o. je 2004. godine kupila opremu i obnovila proizvodnju postojeće tvornice u Rujevcu s godišnjim kapacitetom od cca 2,000.000 m² pločica za vanjska i unutrašnja oblaganja. Instalirana je najsuvremenija oprema za proizvodnju keramičkih pločica dimenzija 25cm*40cm za zidna i 33cm*33cm za podna oblaganja. U 2008. godini povećan je kapacitet proizvodnje bordura na 1,500.000 komada pločica u tvornici Orahovica. Obje tvornice opremljene su tehnikom i tehnologijom koje ih svrstavaju u red najsuvremenijih tvornica keramičkih pločica u ovom dijelu Europe.

B 1. Procesni model i primjena normi upravljanja

KIO Keramika d.o.o. sustavno gradi TQM sustav na osnovi normi upravljanja procesom. Od 1998. godine posluje prema normama Sustava upravljanja kvalitetom ISO 9001. U tvrtci KIO Keramika d.o.o. uvedena je i provedena certifikacija norme ISO 9001 koja se odnosi na sustave upravljanja kvalitetom i norma ISO 14000 koja se odnosi na sustav upravljanja okolišem. Sustav ISO 9001 certificiran je i 2001, 2003 i 2007 godine a sustav ISO 14000:2004 certificiran je krajem 2005 godine. Sustav upravljanja kvalitetom i Sustav upravljanja okolišem povezani su u jedinstveni Integrirani sustav

upravljanje definiran dokumentacijom koju sačinjavaju: misija poduzeća, vizija poduzeća, politika upravljanja, priručnik upravljanja, definirani procesi, postupci, radne upute i obrasci.

Procesni model prikazan je blok shemom na slici B1.



Slika B.1. Model procesa – blok shema realizacije proizvodnje

B2. Proizvodni proces

Proces pripreme i realizacija proizvodnje keramičkih pločica definiran je dokumentacijom Integriranog sustava upravljanja KIO Keramika d.o.o. Prema normi ISO 9001:2000 proces pripreme i realizacije proizvodnje definiran je dokumentacijom Sustava upravljanja: priručnikom upravljanja, procesima, postupcima, radnim uputama i obrascima. Proces pripreme i realizacija proizvodnje keramičkih pločica je sustav aktivnosti u kojima se ljudski i materijalni resursi koriste kako bi se definirane ulaze uz kontrolne elemente pretvorilo u ciljane izlaze.

Cilj procesa je proizvesti keramičku pločicu kao finalni proizvod u zahtijevanoj normi kvalitete a pri tome procesom upravljati na način da

- Proces bude troškovno učinkovit odnosno da se ostvare planske količine i planske klase proizvoda uz smanjenje škarta, rastura materijala i energenata
- Proces bude djelotvoran tj. da proizvod odgovara zahtjevima kupca, korisnika, i da su postignuti ciljevi kvalitete na koje ovaj proces utječe
- Proces bude kontroliran na način da postoje nadzorne mjere koje se primjenjuju na aktivnosti u procesu, na resurse, na ulaze i na gotov proizvod, tako da se dobiveni rezultati analiziraju i vrednuju radi stalnog povećanja njegove djelotvornosti.

B2.1. Procesni resursi

Ljudski i materijalni resursi čine osnovicu procesnih resursa. Ljudski resursi su svi djelatnici koji organiziraju, planiraju, provode i kontroliraju sve aktivnosti u proizvodnom procesu. Njihova kvalifikacijska strukture, obučenost, iskustvo, motiviranost i svijest moraju odgovarati zahtjevima i ciljevima procesa i moraju se stalno usavršavati. Zahtjevi za kvalifikacijom pojedinog radnog mjesta postavljeni su uz radne uvjete a uvjerenja o osposobljenosti vode se na obrascima i uvjerenjima o informiranju i upoznavanju djelatnika sa dokumentacijom.

Materijalni resursi su sva prikladna i prema obrascu PO-09-03 održavana procesna oprema, mjerna i mjerilačka oprema te građevinska infrastruktura poput zgrada i pripadajućih komunalija.

B2.2. Opis *procesa*

Proizvodni proces definiraju postupci dati u dokumentima pod oznakom PO-09-01 i PO-09-02 te pripadajuće radne upute. Radne upute definiraju način i razloge izvođenja aktivnosti u pripremi i realizaciji proizvodnje. Postupak PO-09-01 određuje način provedbe aktivnosti kojima će se osigurati realizacija proizvoda u potrebnim količinama, prema potrebnoj dinamici, sa traženom kvalitetom i prihvatljivim troškovima. Procesom se upravlja na način da se utvrde ključni mjerivi procesni parametri koji daju značajnu informaciju o djelotvornosti procesa odnosno koji služe za pravilno vođenje i kontrolu procesa.

Proizvodnju poroznih zidno-podnih pločica za unutarnja oblaganja na lokaciji Orahovica određuju zahtjevi grupe EN-14411:2003 B III Aneks L, a proizvodnju podnih pločica za vanjska oblaganja s upijanjem ispod 3% određuju zahtjevi grupe EN-14411:2003, Aneks A.

Pločice se proizvode na prikladnoj opremi u tehnologiji monopoljenja po točno utvrđenom redoslijedu tehnoloških operacija uz definirane i kontrolirane parametre procesa i proizvoda sa određenim ljudskim resursima i ciljanim izlazima iz procesa. U svim kontrolnim točkama tehnološkog procesa gdje se registrira nesukladnost postupka se po PO-13-01 a stanje pregleda i ispitivanja poluproizvoda i proizvoda obilježava se po PO-12-01, popravke na robi i procesu provode se prema PO-14-01 i pripadajućim radnim uputama.

B2.2.1. Slijed operacija tehnološkog procesa prešanja pločica

Priprema šlikera (kompozita)

Prema recepturnom nalogu izdanom na obrascu OB-09-02-01 djelatnik na utovarnom stroju obavlja doziranje sirovina u dodavač smješten na vagi. Odvagane komponente se sustavom transportnih traka šaržiraju u kuglične mlinove prema RU09-01-130. Radnik na pripremi šlikera preko vodomjerala dozira vodu mlinovima. Odmjerene komponente i voda melju se u mlinovima do određenog stupnja usitnjenosti prema OB-04-01-13. Djelatnik u pripremi uzima samljeveni kompozit tzv. šliker i odnosi ga na analizu u KTP gdje se provjerava „ostatak na situ“ kao finoću mljevenja te litarnu težinu po RU-10-02-02. Ukoliko su rezultati ispitivanja u redu djelatnik u pripremi prazni mlin u muljaču po RU-09-01-130. Sustavom crpki i cjevovoda šliker se iz muljače dovodi u „sitostanicu“ gdje prema RU-09-01-130 djelatnik u pripremi obavlja prosijavanje. Prosijani se šliker uvodi u centralne bazene u kojima se izvodi homogenizacija i ponovna kontrola litarne težine.

Priprema granulata

Homogenizirani šliker se iz centralnog bazena pomoću visokotlačne membranske crpke, a uz kontrolu djelatnika na atomizeru, raspršuje u atomizeru u granule i suši strujom vrućih plinova do određene vlažnosti prema RU-09-01-137 i 138. Kontrola vlažnosti granulata obavlja se prema RU-10-02-03 u kontroli tehnološkog procesa svakih sat vremena i po RU-10-02-12

kontinuirano. Formirani granulat pada na prijenosnik ispod lijevka atomizera i preko elevatora i reverzibilnog prijenosnika skladišti se u četiri silosa za odležavanje granulata. Iz spomenutih silosa sustavom prijenosnih traka granulat se doprema u silose preša prema RU-09-01-139.

Prešanje granulata u pločice i sušenje pločica

Granulat se iz silosa preša dovodi u preše gdje se prema zadanim parametrima određenim nizom radnih uputa obavlja prešanje pločica. Kontrola otpreska se provodi prema RU-10-02-06, 07 i 08 u laboratoriju te od strane djelatnika na preši. Djelatnik kontrolira debljinu otpreska, klinavost, cjelovitost i čistoću otpreska. Otprešane pločice automatski se izuzimaju na transportnu traku kojom odlaze u vertikalnu sušaru. Sve to kontrolira djelatnik na preši i predradnik. U sušari se u struji toplog zraka pločice suše i izlaze iz sušare s unutrašnjim sadržajem vlage do najviše 1% po OB-04-01-05. Kontrolu vlaga na izlazu iz sušare obavlja kontrola tehnološkog procesa po RU-10-02-09.

Priprema engoba, glazura, pasta i sita

Prema recepturnim nalogima koji se izdaju na način opisan u postupku PO-09-02, djelatnici u pripremi glazura i engoba pripremaju potrebne glazure i/ili engobe a prema RU-09-01-145. Nakon propisanog vremena mljevenja djelatnik uzima uzorak samljevene glazure ili engobe i donosi ga u laboratorij na kontrolu kvalitete. Kontrolor tehnološkog procesa ispituje prema RU-10-02-02 kvalitetu glazure ili engobe i na osnovu rezultata ispitivanja donosi odluku o tome odgovara li glazura ili engoba, nakon čega se po RU-09-01-147 sadržaj prazni u odgovarajući bazen ili se u slučaju neispravnosti postupka prema PO-13-01. Djelatnik u pripremi pasta dobiva od svog voditelja ili rukovoditelja proizvodno tehnološkog sektora tjedni termin plana proizvodnje. Na osnovu njega, tehnoloških propisa za predmetne artikle ili podataka dobivenih od OB-04-01-10 priprema odgovarajuće paste. Evidenciju o pripremi vodi se na OB-09-01-37 a pasta se priprema prema RU-09-01-211. Djelatnik koji radi na izradi sita dobiva od svog voditelja ili rukovoditelja proizvodno tehnološkog sektora tjedni termin plana proizvodnje. Na osnovu njega i tehnoloških propisa za izradu zahtjevanih artikala djelatnik priprema sita po RU-09-01-200 do 206. Izrađeno sito djelatnik evidentira na OB-09-01-36, kontrolira ga, obilježava i odlaže na policu.

Glaziranje pločica

Odmah nakon izlaska iz sušare pločice se sustavom traka vode na glazir linije. Prema RU-09-01-155 do 166 i na osnovu tehnoloških parametara za glaziranje postavljenih za svaki proizvod provodi se faza glaziranja. Sve radnje provode predradnici i djelatnici na glaziranju. Kontrolu kvalitete glaziranja provodi voditelj, predradnik i sami djelatnici na glaziranju. Označavanje stanja pregleda i ispitivanja vrše se prema RU-12-01-02.

Punjenje vagona glaziranim pločicama

Glazirane pločice automatski ulaze u vagone s valjcima. Vagone na položaj za punjenje dovozi djelatnik za punjenje vagona, koji centrira vagon i kontrolira kvalitetu ulaska pločica u vagon prema RU-09-01-167, 168. Napunjeni vagoni se automatskim optokom roba dopremaju do ulaska u peć prema RU-15-01-05.

Paljenje glaziranih pločica

Paljenje glaziranih pločica obavlja se propisanim tehnološkim procesom u ruli pećima s valjcima, koje su grijane zemnim plinom. Proces paljenja počinje pražnjenjem vagona i punjenjem peći s glaziranim sirovim pločicama na način opisan u RU-09-01-90 i 91. Proces paljenja sirovih glaziranih pločica obavlja se u cilju postizanja propisanih karakteristika prema standardu Hrn EN 14411 B III dio L koje se postižu pečenjem.

Vođenje procesa paljenja obavlja se na način opisan u radnim uputama RU-09-01-85, 90, 91, 95, 96 i 98. Kako na pravilan rad peći i neometan proces paljenja pločica utječe više ometajućih čimbenika oni su određeni i za njihovo otklanjanje utvrđeni su odgovarajući postupci i radnje opisane u sljedećim radnim uputama: RU-09-01-86, 87, 88, 89, 92, 93 i 94. U cilju postizanja odgovarajuće kvalitete pločica u procesu paljenja obavljaju se kontrole procesa na način opisan u radnim uputama RU-09-01-99 i RU-01-97 i 101. Za pravilan rad peći određene su preventivne radnje i otklanjanje kvarova koji se obavljaju na način opisan u radnim uputama RU-09-01-97 i 101. U istim radnim putama opisana je i odgovornost za pravilno vođenje procesa paljenja pločica.

Sortiranje i pakiranje pločica

Nakon izlaska iz peći pločice se sustavom prijenosnih traka ili vagonima dopremaju do stolova za sortiranje. Stolovi za sortiranje su tako opremljeni da imaju odgovarajuće osvjetljenje prema RU-04-01-03 uz koje djelatnik koji obavlja klasifikaciju može vidjeti sve vizualne greške koje definiraju klasu prema RU-10-03-06. Prema RU-09-01-01 djelatnik na sortirnom stolu obavlja markiranje prema kojem se pločice raspoređuju u odgovarajuće klase. Pored vizualnih grešaka klasu određuje i kvaliteta dimenzija i plošnost koje se provjeravaju prema RU-10-03-02 u kontrolnom tehnološkom procesu a prema zahtjevima danim u tablici broj 1 u RU-10-03-06.

Rezultat ovog ispitivanja kontrolor tehnološkog procesa usmeno priopćava predradniku sortiranja ili djelatnici na sortiranju koja na osnovu tog podatka određuje status pločica koje se nakon toga pakiraju u kutije. Pakiranje proizvoda KIO d.d. obavlja se prema PO-15-03. Kontrolu kvalitete sortiranja i pakiranja provode kontrolori tehnološkog procesa prema RU-10-30-01. Ukoliko razina sortiranja ne zadovoljava zahtjeve klase, paleta sa zapakiranim pločicama se vraća na presortiravanje i s njome se postupa prema PO-13-01. Paleta čiju je kvalitetu odobrio kontrolor svojim potpisom i datumom zamata u foliju djelatnik na stroju za zamatanje. U foliju zamotane palete predaje voditelj odjela ili predradnik na skladište gotovih proizvoda.

B2.2.2. Slijed operacija tehnološkog procesa ekstruzije

Sušenje sirovina u rotacijskoj sušari

Sve sirovine koje treba sušiti zasebno se preko sandučastog dodavača, transportera i „krašera“ uvode u rotacijsku sušaru gdje se suše do približno 8% vlage. Osušene sirovine skladište se u odjeljke, boksove. Osušene sirovine se pripremaju kao kompozit tako da se obavlja njihovo doziranje u koševе vаgа te se nakon toga melju u mikronizirani prah. Podešavanje otvora koša te brzine istjecanja materijala preko protočnih vаgа komponenti oblikuju propisani kompozit. Kompozit se zatim sustavom transportera vodi u impaktni mlin gdje se smjesа usitnjava, zatim elevatorom prebacuje u mali silos kao „hranilicu“ pendularnog mlina. U pendularnom mlinu se obavlja daljnje sušenje kompozita i meljava mikroniziranog praha, finoće

oko 75% čestica manjih od 80 mikrona. Samljeveni kompozit podiže se podtlakom iz mlina i prenosi u procesni filter, a zatim elevatorom doprema u silose.

KS**PTS****SR****KTP****KS NABA**

Slika B2. Realizacija proizvodnje po sektorima u KIO Keramika d.o.o.

Priprema glinenog tijesta i ekstruzija

Priređeni mikronizirani kompozit se iz silosa preko protočnih vaga i sita transportira u prvi mješač gdje se dodaje voda uz pomoć koje se oblikuje glineno tijesto. Tijesto se s vlagom od približno 22% briketira i sprema u spremnik (boxfider) radi homogenizacije i miješanja s otpadom. Zatim se transporterom upućuje u drugi mješač iznad ekstrudera gdje mu se po potrebi korigira vlaga. Usitnjeno i isjeckano tijesto uvodi se nakon mješača u vakuum komoru gdje se iz tijesta isisava zrak u svrhu maksimalnog zgušnjavanja. Vakumirano tijesto se zatim uvodi u ekstruder i uz optimalni tlak od 25-26,5 bara istiskuje kroz alat u željeni oblik trake iz koje se na sjekačici i preši isijecaju određeni oblici pločica.

Sušenje u horizontalnoj sušari

Formirani sirovi proizvod se transportnom trakom dovodi u horizontalnu sušaru. Tu se suši po određenoj krivulji sušenja do gubitka vlage ispod 3%.

Glaziranje osušene ekstrudirane robe

Glaziranje se obavlja nanošenjem glazure i engobe diskovima. Dekorira se „Multirolom“. Poglazirana i dekorirana roba uvodi se u vagone s valjcima.

Pečenje glazirane ili neglazirane ekstrudirane robe

Po utvrđenoj krivulji pečenja u peći na valjke peče se predmetna roba. Na izlazu iz peći pečena roba se slaže u posebne odjeljke, boksove.

Sortiranje i pakovanje

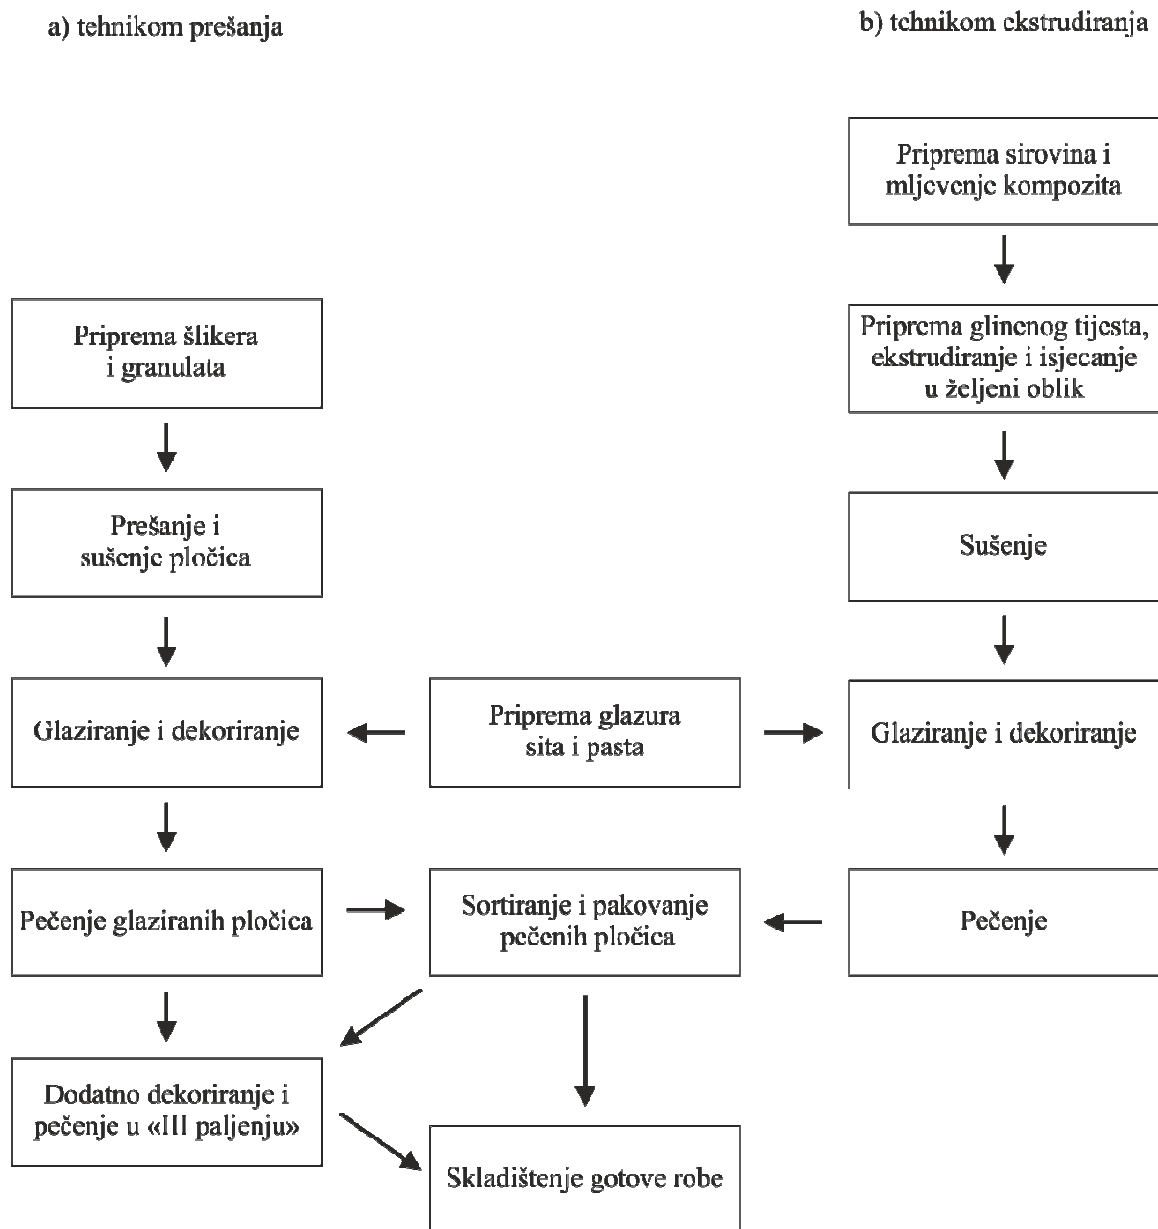
Iz boksova se pečena roba upućuje na liniju za sortiranje. Tu se klasira i na kraju linije pakuje u kutije koje se uz paletizator slažu na palete koje se zatim omataju u foliju i predaju na skladište.

Na slici B2. prikazana je blok shema realizacije proizvodnje vezana za sve sektore KIO Keramika d.o.o.

Slika B2. prikazuje niz aktivnosti u proizvodnji tehnikom prešanja i tehnikom ekstrudiranja. Sve navedena aktivnosti u procesu realizacije proizvodnje obrađene su pojedinačno po procesnom modelu kao međuovisni procesi u kojima je izlaz iz jednog procesa ulaz u drugi proces.

Slika B3. prikazuje aktivnosti pri realizaciji proizvodnje postupkom prešanja i postupkom ekstrudiranja.

AKTIVNOSTI PRI REALIZACIJI PROIZVODNJE



Slika B3. Grafički prikaz aktivnosti pri realizaciji proizvodnje

B3. Proces kontrole kvalitete proizvoda

U KIO Keramika d.o.o. se primjenjuje Proces mjerenja i ocjenjivanja (PC-10) koji je dio Integriranog sustava upravljanja radi

- a) Dokazivanja sukladnosti parametara procesa sa zadanim parametrima
- b) Dokazivanje sukladnosti proizvoda, koje se obavlja u Sektoru SUK, odjelu KTP prema PC-10-1
- c) Praćenje i ostvarivanje postignutih ciljeva, procesa i postupaka radi osiguranja sukladnosti Sustava upravljanja kvalitetom i njenog stalnog poboljšavanja sukladno TQM konceptu.

Aktivnosti nadziranja u proizvodnji odvijaju se po točno utvrđenom redoslijedu tehnoloških operacija uz definirane i kontrolirane značajke procesa i proizvoda. Djelatnici i voditelji nadziru proces proizvodnje i kontroliraju proces te parametre procesa da bi finalni proizvod zadovoljio zahtjeve kupca i tehničke norme.


U KIO Keramici d.o.o. postoje dvije vrste kontrole: kontinuirana kontrola i kontrola na mah (zvana blic kontrola). Kontinuiranu kontrolu obavljaju djelatnici u procesu proizvodnje. U dokumentaciji Sustava upravljanja radnim su uputama propisani svi načini obavljanja radnih operacija u svim fazama uz parametre koji se prate. U tehnološkim propisima koji su dobiveni iz Sektora Razvoja na obrascu OB-04-01-05 zadani su intervali tolerancija za svaki parametar u međufaznoj kontroli. Djelatnici moraju te parametre održavati unutar zadanih tolerancija.

Kontrolom na mah koju obavljaju djelatnici KTP i SUS-a izvodi se uzorkovanje na bazi slučajnog uzorka prema normi HRN-ISO 2859/1 – 1996 i prema planu kvalitete u čitavom proizvodnom procesu. Kontrolori obavljaju kontrolu ulaza u proces, međufaznu kontrolu i završnu kontrolu. Kontrola tehnološkog procesa radi prema propisanim radnim uputama i planovima kontrole koji su dnevni, tjedni i mjesečni u skladu sa standardima HRN – EN – 14411:2004.

Ulazna kontrola provjerava sve sirovine koji ulaze u proces proizvodnje tako da u proces ulazi samo supstancija dobre kvalitete. Međufazna kontrola prati sve parametre međufaze tako

da se prijelazi između proizvodnih faza odobravaju samo ako su rezultati mjerenja prethodne faze unutar tolerancija navedenih na OB-04-05. Završna kontrola obavlja se za sve palete prve klase prema normi HRN – ISO 2859/1 – 1996 prema planu uzorkovanja u završnoj kontroli. Prema standardu se uzima određeni broj pločica ovisno o veličini serije te se na osnovu broja dobrih i loših paleta pušta u prodaju ili vraća ponovno na ručno sortiranje. Završna kontrola, ispitivanje na gotovim pločicama se također radi prema standardu HRN – EN – 14411:2003, koji se opet poziva na EN, odnosno na ISO standard, kojima se točno određuju vrste i načini ispitivanja. Kontrolne točke u procesu proizvodnje prešanjem date su na slici B.4.

KONTROLNE TOČKE U PROCESU PROIZVODNJE - PREŠANJA



Slika 7.

Slika B4. Kontrolne točke u procesu proizvodnje prešanjem

Dodatak C:

Analiza motiviranosti radnika u KIO Keramika

Zamisao vođenja kvalitete u procesu proizvodnje keramičkih pločica zasniva se na striktnom pridržavanju postupaka u procesu te na pouzdavanju u pravodobno praćenje nadzor i provedbu mjera kvalitete prema postojećim pravilnicima o kvaliteti. Ponašanje proizvodnog procesa i odgovarajuća kvaliteta krajnjeg proizvoda jako ovise o cjelovitoj organizaciji firme, ugrađenoj procesnoj tehnologiji i proizvodnoj disciplini. Da bismo uspjeli istražiti pravilnosti u rezultatima rada postrojenja i omogućiti detektiranje kritičnih točaka za proces kvalitete mora se izvršiti niz mjerenja i prostudirati njihove parametre.

Zbog međudjelovanja zaposlenika i proizvodnog procesa koje možemo shvatiti kao mogući nastanak dodatnog procesnog poremećaja, potrebno je odvojeno istražiti motiviranost i osposobljenost zaposlenika, dakle dobiti trajnu mjeru njihove motiviranosti, te stanje kvalitete proizvoda, dakle dobiti uvid u trenutnu mjeru ispravnosti rada procesne opreme.

C1. Postavka problema osposobljenosti i motiviranosti zaposlenika

Vrijeme osposobljavanja radnika je svakako ključan problem za što bržim dobivanjem rezultata implementacija novih investicija. Pored osposobljavanja direktnih izvršilaca potrebno je osposobiti i višu razinu upravljanja, tj. rukovodioci, koji također nemaju iskustva s uvođenjem novih tehnika i tehnologija. Osposobljavanje svih onih koji su odgovorni za uvođenje novih tehnika i tehnologija vrše monter i tehnolozi proizvođača opreme kao i sirovine koje se uvoze iz inozemstva. Kod toga je veliki problem dislociranost proizvođača (Italija, Španjolska), poznavanje jezika te privrženost starim tehnikama i tehnologijama. Želim napomenuti da u Hrvatskoj nema niti jedne stručne-obrazovne ustanove koja bi obrazovala potrebne kadrove za tu vrstu industrijske proizvodnje. Rješenje vidim u formiranju određenih obrazovnih grupa specijaliziranih za takva zvanja pri srednjoškolskim i višim učilišnim centrima najbližim lokaciji industrijske proizvodnje. Također potrebnim novim zapošljavanjem stručno visoko obrazovanih kadrova.

C2. Postojeća stanja i rješenja pri motiviranosti zaposlenika

U drugim europskim i svjetskim državama tradicija i razvoj proizvodnje keramičkih proizvoda je znatno duža nego kod nas. Razvoj tehnika i tehnologija bio je normalan slijed i razvoj u razvijenim kapitalističkim zemljama kao što su Italija i Španjolska. Tek raspadom Jugoslavije, bilo je dozvoljeno uvoziti nove tehnike i tehnologije, npr. u Italiji postoji preko 400 tvornica za proizvodnju keramičkih pločica u jednoj uskoj pokrajini Sassou te je osposobljavanje i fluktuacija zaposlenika bila normalna stvar. Dizajn, odnosno tržište kao i proizvođači novih tehnika i tehnologija su se maksimalno trudili za njihova poboljšanja u kvaliteti i kvantiteti proizvoda. Raspadom tržišta Jugoslavije, otvaranje prema ino tržištima zahtijevalo je brzo uvođenje novih tehnika i tehnologija radi konkurentnosti proizvoda. Dakle, pored osposobljavanja zaposlenika potrebno je bilo i rušiti psihološke barijere, odnosno odbojnosti prema novim, nepoznatim, suvremenim tehnikama i tehnologijama. Privatizacija tvrtki dovela je do razmišljanja zaposlenika da su dosadašnju tehniku i tehnologiju oni financirali te da su i oni onda vlasnici istog, a svaka nova investicija je trošenje sredstava koje bi oni trebali dobiti za povećanje svojih plaća. Takav pristup je bio vrlo negativistički prema uvođenju novih tehnika i tehnologija za razliku od razvijenog Zapada.

C3. Zatečeno stanje i organizacijska struktura

Poslovanje organizacije opterećeno je financijskim poteškoćama pa se posluje u specifičnim ekonomsko-političkim okolnostima koje su opisane kao karakteristične za tranzicijsku Hrvatsku potkraj 20. stoljeća kako opisuju Čižmar [C1] te Sirotković [C2]. Postoje mnogi čimbenici koji, osim što utječu na poslovanje, definiraju stavove i mišljenja zaposlenika. U takvom okružju izrada, provedba i obrada ankete nije jednostavan terenski posao zapažanja i izbora primjerenih ključnih pojmova, već je to dinamičan i kompliciran proces koji zahtijeva vrlo intenzivne i pažljive pripreme istraživanja. Također, interpretacija dobivenih rezultata istraživanja zahtijeva puno razumijevanja i znanja o stvarnoj situaciji u promatranoj organizaciji i o vanjskim čimbenicima koji utječu na poslovanje. Primjena rješenja koja proizlaze iz analize rezultata istraživanja ovisna je o gore navedenim čimbenicima.

U trenutku istraživanja u organizaciji je zaposleno ukupno 472 zaposlenika. Postoje dva geografski odvojena pogona za proizvodnju pločica. Pogon «Orahovica», strukturno složeniji, ima pet razina (ne računajući Upravu poduzeća na čelu koje je predsjednik Uprave) i šest glavnih sektora: proizvodno tehnički, ekonomsko financijski, komercijalni, sektor razvoja, sektor upravljanja sustavima, sektor za ljudske resurse te ured Uprave. Proizvodno tehnički sektor sastoji se od dvije proizvodne jedinice za prešane i za ekstrudirane pločice te tri logističke jedinice: elektro održavanje i energetiku, strojarsko održavanje i odjel informatike. Radna jedinica proizvodnje ukupno ima šest podjedinica. Pogon «Rujevac» strukturno je jednostavniji i ima tri razine i tri sektora koji su strukturom identični pogonu «Orahovica». u oba pogona rad se odvija u tri smjene. Proizvodnja je radno intenzivne prirode no zaposlenicima značajno pomaže automatizacija i robotizacija proizvodnih linija.

C3.1 SPECIFIČNOSTI KVALITATIVNOG I KVANTITAVNOG ISTRAŽIVANJA ORGANIZACIJE

Svi kvalitativni podaci – od općih poput: organizacijska shema, poslovni i komunikacijski procesi, rabljenje tehnologije i tehnološke operacije, proces rukovođenja i kontrole kvalitete; pa sve do specifičnih poput: proizvodnja, tvrtka, napredovanje, zarada, itd. – mogu se pretvoriti u razložne kvantitativne podatke čija će analiza i interpretacija omogućiti opisivanje i poboljšanje rukovođenja Organizacijom.

Općenito gledano, kvantitativne metode po svojoj su prirodi analitičke metode te ne omogućuju objektivnu sintezu stečenih saznanja. Nasuprot njima, metode multivarijantne analize, odnosno metode koje omogućavaju istovremenu analizu više obilježja, u svojoj su biti sintetizirajuće [C3, C4]. Tablica 5.1 u stupcima dva i tri prikazuje usporedbu značajki kvantitativnih i kvalitativnih metoda. Značajke kvalitativnih metoda koje navode Amaratunga i suradnici (2002., 20) [C5] predstavljaju osnovnu vodilju u ovom radu te su objašnjene iz konteksta percepcije stvarnog stanja (stupac 1).

Tablica C.1 - Značajke kvantitativnih i kvalitativnih metoda, Izvor: Amaratunga i suradnici (2002., 20), stupci (2) i (3)

Stvarno stanje (1)	Kvantitativne metode (2)	Kvalitativne metode (3)
U poslovnim procesima stvarna komunikacijska situacija odstupa od racionalne ili idealne	Upit dolazi izvana	Upit dolazi iznutra
Zaposlenici razložno djeluju na apobetičkoj razini	Poduprte nizom epistemoloških osnova potpuno različitim od kvalitativnog istraživanja	Pokušaj da se uzmu u obzir razlike među ljudima
Pokušaj racionalizacije procesa putem strukturnih i komunikacijskih procesa	Jesu li to samo različiti načini dobivanja istih rezultata?	Ciljaju na fleksibilnost i nedostatak strukture kako bi omogućila vezu teorije i koncepata
Povratna informacija kao ključ poimanja komuniciranih pojmova	Uključuju praćenje različitih načina znanstvenog istraživanja	Rezultati se, kroz teoretsko poopćavanje, mogu smatrati "dubokima, bogatima i smislenima"
Metoda uparivanja pojmova iz kvalitativnih varijabli daje kontekstne informacije (vrijednost).	Za rezultate se može reći da su "grubi opći podaci"	Induktivne – gdje se prijedlozi ne dobivaju samo iz prakse ili iz literature nego i iz ideja
Ključni pojmovi nužni su za razložno djelovanje organizacije		Pristup istraživanju društvenog svijeta koji treba opisati i analizirati kulturu i ponašanje ljudi i njihovih grupa iz perspektive onih koji su predmet proučavanja

U izradi hipoteza te pri provođenju ovoga istraživanja bitne su sljedeće činjenice vezane uz kvantitativna i kvalitativna istraživanja:

- 1) Povezivanje zaposlenika s organizacijskim identitetom i poslovnim procesima predstavlja recipročno razumijevanje značenja riječi i koncepata unutar Organizacije dok pravilno funkcioniranje metakomunikacije objašnjava da svaki pojedinac mora imati dovoljno "resursa" ili mogućnosti, odnosno vizije koja mu omogućava što objektivnije sagledavanje situacije [C10]
- 2) Jasno definirana metodologija i znanstveni principi istraživanja; dobro isplanirano istraživanje na temelju vizije njegove svrhovitosti; rabljenje potpunih i cjelovitih kvalitativnih podataka koji opisuju svakodnevne i uobičajene događaje unutar Organizacijskog okruženja [C5, C6, C7].
- 3) Određena pravila i koraci kvalitativnog istraživanja [C8], zbog mogućnosti obuhvata procesa komunikacije odnosno procesa unutar strukture Organizacije.
- 4) Pridržavanje koncepata valjanosti, pouzdanosti, mogućnosti poopćavanja i pažljivosti [C9]
- 5) Komplementarnost kvalitativnog i kvantitativnog istraživanja te pozitivistički pristup koji se objašnjava objektivnim mjerenjima kojima se omogućuje iskaz o uzrocima i posljedicama [neke pojave, npr. procesa komunikacije] [C5]

Dakle, ocjenjivanje kvalitativnih pojmova pokušaj je obuhvaćanja mišljenja o procesima u organizaciji putem povratne informacije ili pristupom «bottom-up». Za razliku od klasičnih kvalitativnih istraživanja «zadovoljstva» ili ispitivanja «radne atmosfere», kvalitativnim istraživanjem moguće je izbjeći apstraktnu semantičku percepciju pojmova od strane zaposlenika te osigurati da su pojmovi percipirani na apobetičkoj razini trenutnog odnosa zaposlenik-Organizacija.

C3.2 IZRADA I PROVEDBA ANKETE

Ključni pojmovi odabrani za izradu ankete prikupljeni su izborom najčešćih odgovora zaposlenika o njima najvažnijim pitanjima u Organizaciji. Od 14 pojmova koji su upareni dobiven je 91 par ključnih pojmova. Pri izradi ankete se vodilo računa o jednostavnosti i

razumljivosti. Postavljeno je jedno univerzalno pitanje: «Kako ocjenjujete da su upareni pojmovi sukladni ili bliski?» Svi parovi su postavljeni na dvije stranice A4 formata, a odgovori su postavljeni putem skale od 0 do 10, te su ostavljena mjesta za označavanje željenog odgovora. Odgovor 0 je označavao najmanju bliskost, dok je odgovor 10 označavao najveću bliskost. Ključni su pojmovi u anketi definirani te je dodatno razjašnjen njihov odnos prema Organizaciji / zaposlenicima.


Anketi su pristupila 335 zaposlenika ili 79,76 % od ukupnog broja raspoloživih zaposlenika u vrijeme provedbe istraživanja. Anketa je vrlo jednostavna i razumljiva, budući da za svih 91 uparenih pojmova sadrži jedno univerzalno pitanje. Pri provedbi ankete, s obzirom na razumijevanje pitanja i sadržaja, nismo imali nikakvih ograničenja jer su i sadržaj i pitanja prilično jednostavni te prethodno definirani. Sama provedba je također jednostavna. Upitnik je prema mogućnostima i uvjetima samostalno ispunjavan u malim grupama. Kako su za odgovore postavljene rubrike za označavanje željenog odgovora, vrijeme potrebno za pojedine odgovore bilo je relativno kratko, najčešće između 15 i 20 minuta.

U naknadnoj obradi anketa uočeno je sljedeće: 1) 11 nevaljelih anketa zbog izrazite nelogičnosti odgovora. Stoga postoje 324 odgovora na anketu na kojima je temeljeno ovo istraživanje. 2) 17 nepotpuno ispunjenih zaglavlja anketa čiji su podaci ili naknadno ekstrapolirani ili su podaci uključeni u prvi višu organizacijsku razinu s obzirom na mogućnost interpretacije rezultata. 3) Od ukupnog broja svih parova pojmova (29.484) odgovorenenih je 28.455 ili 96,51 %. S obzirom na metode istraživanja i analize, nepotpune ankete nisu isključene iz obrade.


C3.3 REZULTATI ISTRAŽIVANJA MOTIVIRANOSTI ZA KVALITETNU PROIZVODNJU

Rezultati koji se prikazuju izraženi su na razini sljedećih organizacijskih segmenata: 1) cijelog kolektiva bez sektora proizvodnje, te 2) sektora proizvodnje. Razmatraju se istovremeno sve razine i radne podjedinice unutar ukupne strukture navedenih sektora. Kao najprimjerenija metoda klasteriranja izabrana je *Complete linkage*. Prosječne vrijednosti ocjena pojedinih pojmova (odnose se na aritmetičke sredine svih ocjena parova pojmova u kojima je određeni

pojam tvorbeni, u daljnjem tekstu srednjaci) pokazuju koje su ocjene svakom pojmu dane kada izračunamo srednjak ocjena svih parova u kojima sudjeluje određeni pojam. Visina ocjene općenito utječe na bliskost pojmova. Bez analiziranja bliskosti pojmova multidimenzionalnim skaliranjem, samom vrijednošću aritmetičke sredine ocjena pojedinih pojmova, nemoguće je kvalitetno analizirati komunikaciju i procese u Organizaciji. Međutim, općenito se viša ocjena pojmova može interpretirati kao bolja svjesnost o ulozi tih pojmova u proizvodnom procesu ili komunikaciji unutar Organizacije.



Slika C1. Klaster analiza na razini cijele Organizacije bez proizvodnog sektora



Slika C2. Klaster analiza na razini proizvodnog sektora

Slike C1 i C2 prikazuju rezultate klaster analize za 14 ključnih pojmova prema odgovorima anketiranih na razini cijele Organizacije bez proizvodnog sektora i na razini samo proizvodnog sektora. Ordinatna os predstavlja udaljenost pojmova na mogućoj skali odgovora od 0 do 10. Apscisna os prikazuje pojmove. Manje vrijednosti prikazuju veću bliskost.

Osnovna ideja klaster analize, naime, je u rješavanju zadatka grupiranja elemenata (jedinki, subjekata, pojava i sl.) na osnovi njihovih obilježja ili atributa tako da elementi unutar grupe, odnosno klastera, imaju visok stupanj "prirodne asocijacije", dok su istovremeno tako formirani skupovi, odnosno klasteri, međusobno "relativno udaljeni" [C4]

Procjena točnosti rezultata predstavlja zaseban zadatak [C5], a u ovom je radu za to korišten koeficijent stresa. Prema definiciji, mjera uspješnosti reduciranja dimenzija prostora sastoji se od sume kvadrata odstupanja multidimenzionalnim skaliranjem dobivene konfiguracije od originalne i mjeri se numeričkim koeficijentom nazvanim stres (iskrivljenje). Za analizirane organizacijske segmente koeficijent stresa je manji od 0,2. Stoga su dobivena rješenja za trodimenzionalnu reprezentaciju udaljenosti među objektima zadovoljavajuća, tj. originalu vjerna geometrijska konfiguracija može se predstaviti u tom prostoru.

Tablica C2 - srednjaci udaljenosti

Organizacija bez proizvodnje		Sektor proizvodnje	
Zarada	6,5146	Zarada	7,1233
Napredovanje	6,1523	Ovlasti	6,7813
Ovlasti	5,8923	Obrazovanje	6,7531
Obrazovanje	5,8500	Napredovanje	6,7071
Kupac	5,7277	Radni uvjeti	6,6838
Komunikacija	5,6969	Komunikacija	6,6114
Efikasnost	5,6585	Menadžment	6,5169
Menadžment	5,6385	Kupac	6,4526
Odgovornosti	5,6215	Efikasnost	6,3741
Radni uvjeti	5,5785	Kvaliteta	6,3401
Kvaliteta	5,4738	Tvrtka	6,3231
Tvrtka	5,4500	Tehnologija	6,1667
Tehnologija	5,3315	Proizvodnja	6,1193
Proizvodnja	5,3092	Odgovornosti	6,1167

U tablici C2 prikazani su srednjaci udaljenosti pojmova na temelju slika C1 i C2. Vrijednosti iz ankete gdje se tražila bliskost ili sukladnost pojmova su invertirane. Veći brojevi

prikazuju veću udaljenost, odnosno manju aritmetičku sredinu ocjena danih određenom pojmu u anketi. Stoga pojam *zarada* ima najmanji srednjak dok pojam *proizvodnja*, odnosno *odgovornosti* najveći.

Literatura za dodatak C

[C1] Čižmar, S., Poljanec-Borić, S. (1997.), Privatizacija turističkog sektora u Hrvatskoj u tranzitornim i ratnim uvjetima. *Turizam*, vol. 45., pp. 289-300.

[C2] Sirotković, J. (1996.), *Gospodarstvo Hrvatske. Golden marketing*, Zagreb.

[C3] Cellier, F. E. (1996.), Mixed quantitative and qualitative modeling: means for dealing with system uncertainty. *15th Benelux Meeting on Systems and Control*, pp.111-123., Mierlo, Nizozemska.

[C4] Szilovicza, L. (2006.), Elementi klaster analize, kolegij Analiza podataka, Filozofski fakultet Sveučilišta u Zagrebu.

[C5] Amaratunga, D., Baldry, D., Sarshar M., Newton, R. (2002.), Quantitative and qualitative research in the builet environment: aplication of "mixed" research approach. *Work Study*, Volume 51, Number 1, 2002., pp. 17-31.

[C6] 36.Eldabi, T., Irani, Z., Paul, R. J., Love, P., (2004.), Quantitative and qualitative decision-making methods in simulation modeling. *Management Decision*, 40/1, pp. 64-73.

[C7] Cassel, C., Symon, G., Buehring A., Johnson P. (2006.), The role and status of qualitative methods in management research: an empirical account. *Management Decision*, Vol. 44, No. 2, pp. 290-303.

[C8] D. Jović, D. Krmpotić, V. Hocenski (2006). Kvantitativna analiza interne komunikacije: slučaj rukovođenja keramičkom industrijom.

[C9] Stenbacka, C. (2001.), Qualitative research requires quality concepts of its own. *Management Decision* 39/7, pp. 551-555.

[C10] Brajša, P. (1993.), Menadžerska komunikologija. DRIP, Varaždin-Zagreb.


Dodatak D Impaktogrami na prešama, entropije i interpretacije rezultata

D1 - Impaktogrami na prešama


Impaktogrami signala s44 do s51 s preša u KIO Orahovica

Slika D1 Impaktogrami s preša 6, 8, 5, 10 i 9

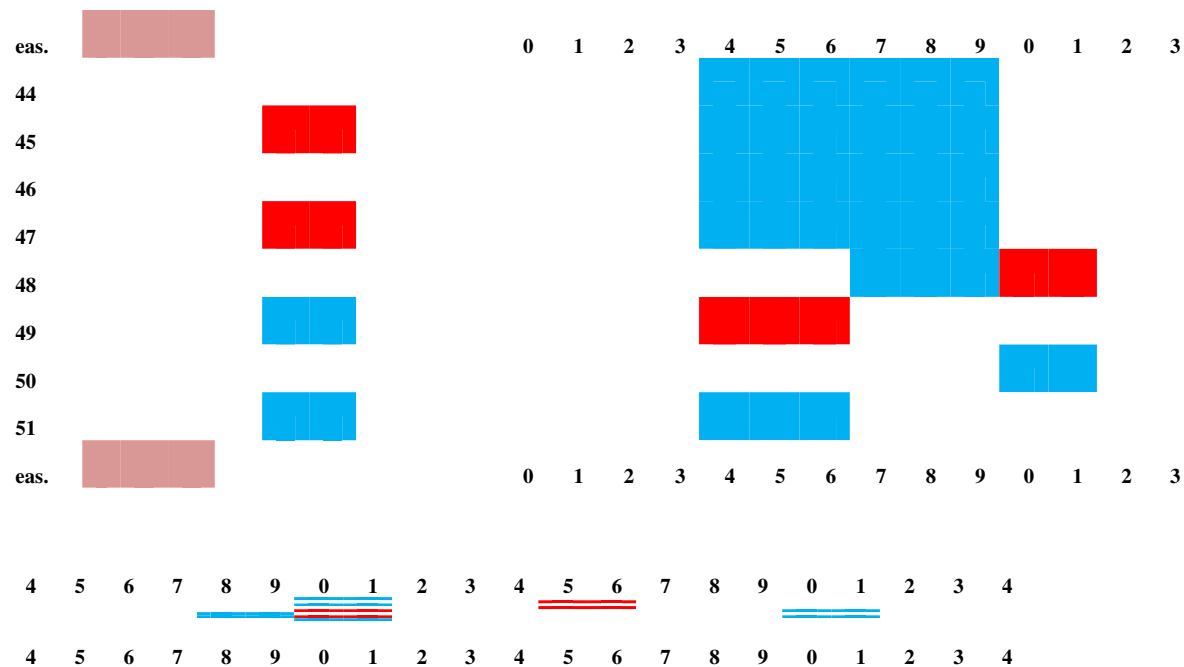
Impaktogram s preše 6




Impaktogram s preše 8



Impaktogram s preše 5




Impaktogram s preše 10



4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6

7 8 9 0 1 2 3 4 5 6 7 8
 7 8 9 0 1 2 3 4 5 6 7 8

Impaktogram s preše 9



4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6

4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6

7 8 9 0 1 2 3 4 5 6 7 8 9 0

7 8 9 0 1 2 3 4 5 6 7 8 9 0

Dodatak D2 Teselacijske entropije na signalima s44 do s51 na prešama 9 i 10

Tablica D1 Entropije signala s44 do s51 na preši 9

4	s4 5	s4 6	s4 7	s4 8	s4 9	s4 0	s5 1	s5
	0	2, 021	0	2, 021	1, 056	0	1, 056	0, 958
	2, 415	0, 797	2, 415	0, 797	0	0	0	0
	2, 156	0, 753	2, 156	0, 753	0	0	0	0
	2, 64	0, 744	2, 64	0, 744	1, 354	1, 412	1, 354	1, 253
	0	0	0	0	0, 584	1, 312	0, 584	0, 542
	0	0	0	0	1, 241	1, 389	1, 241	1, 146
	1, 412	2, 019	1, 412	2, 019	2, 285	2, 243	2, 285	2, 125
	1, 312	1, 837	1, 312	1, 837	2, 054	2, 021	2, 054	1, 925
	1, 389	2, 113	1, 389	2, 113	2, 325	0, 448	2, 325	2, 146
	0	0	0	0	1, 312	0, 712	1, 312	1, 17
	0	0	0	0	1, 95	0, 949	1, 95	1, 74
	0	0	0	0	1, 399	1, 447	1, 399	1, 237
	0	0, 949	0	0, 949	1, 5	1, 562	1, 5	1, 296
	0	0, 894	0	0, 894	0	0	0	0
	0	0, 897	0	0, 897	0	0	0	0
	1, 51	0, 988	1, 51	0, 988	2, 063	2, 093	2, 063	1, 95
	2, 203	1, 968	2, 203	1, 968	2, 342	2, 313	2, 342	2, 258
	0, 789	0, 919	0, 789	0, 919	0, 593	0, 468	0, 593	0, 566
	1, 862	1, 993	1, 862	1, 993	1, 549	1, 268	1, 549	1, 453
	1, 103	0, 708	1, 103	0, 708	0, 988	1, 584	0, 988	0, 914
	1, 162	0, 311	1, 162	0, 311	1, 446	1, 179	1, 446	1, 36
	1, 123	1, 403	1, 123	1, 403	0, 385	0, 75	0, 385	0, 36
	0, 281	0, 562	0, 281	0, 562	0, 861	1, 03	0, 861	0, 798
	1, 326	1, 191	1, 326	1, 191	1, 031	1, 51	1, 031	0, 949
	0	0	0	0	1, 412	1, 498	3, 009	1, 026
	0	0	0	0	0, 933	0, 863	2, 387	0, 648
	0	0	0	0	0, 605	0, 639	0, 302	1, 314
	1, 209	0, 988	1, 209	0, 988	2, 804	1, 51	1, 545	1, 188
	0, 523	0, 43	0, 523	0, 43	2, 425	1, 399	2, 044	1, 111

ANALIZA INFORMACIJSKIH OBRAZACA PROCESNIH SIGNALA POMOĆU EKSPANDIRANE 1D CARNAPOVE ENTROPIJE

1,	0,	1,	0,	3,	1,	3,	1,
104	897	104	897	135	499	135	146
1,	1,	1,	1,	0	0	0	0
855	924	855	924	0	0	0	0
1,	1,	1,	1,	1,	1,	1,	0,
698	757	698	757	253	253	253	949
1,	1,	1,	1,	0,	1,	0,	0,
907	993	907	993	542	17	542	894
0	0	0	0	1,	1,	1,	0,
0	0	0	0	146	216	146	897
0	0	0	0	0	0	0	0
1,	1,	1,	1,	1,	1,	1,	0,
009	054	009	054	412	13	412	881
0,	0,	0,	0,	1,	0,	1,	0,
439	458	439	458	312	49	312	385
0,	0,	0,	0,	1,	1,	1,	0,
917	958	917	958	389	03	389	798
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
1,	0	1,	1,	1,	0	1,	0
531	0	39	158	689	0	689	0
0,	0	0,	1,	0,	0	0,	0
657	0	598	084	721	0	721	0
1,	0	1,	1,	1,	0	1,	0
41	0	275	114	562	0	562	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0,	1,	1,	1,	0	1,	0	1,
881	009	13	484	0	51	0	253
0,	0,	0,	0,	0	0,	0	0,
385	439	49	637	0	648	0	542
0,	0,	1,	1,	0	1,	0	1,
798	917	03	365	0	389	0	146
0,	0,	0,	0,	1,	0	0	0
572	672	572	672	328	0	0	0
0,	0,	0,	0,	1,	0	0	0
544	638	544	638	237	0	0	0

Tablica D2 Entropije signala s44 do s51 na preši 10

4	s4	5	s4	6	s4	7	s4	8	s4	9	s4	0	s5	1	s5
	0,		0,		0,		0,		0		0		0		0
	0		731		0		731		0		0		0		0
	0		0,		0		0,		0		0		0		0

ANALIZA INFORMACIJSKIH OBRAZACA PROCESNIH SIGNALA POMOĆU EKSPANDIRANE 1D CARNAPOVE ENTROPIJE

	72		72				
0	0	0	0	0	0	0	0
0,	0,	0,	0,	2,	2,	2,	1,
988	797	988	797	063	125	063	924
1,	1,	1,	1,	2,	2,	2,	2,
77	8	77	8	342	338	342	238
0,	0,	0,	0,	0,	0,	0,	0,
632	853	632	853	593	475	593	56
1,	1,	1,	1,	1,	1,	1,	1,
429	838	429	838	549	296	549	431
0,	0,	0,	0,	0,	1,	0,	0,
718	61	718	61	988	625	988	897
0,	0,	0,	0,	1,	1,	1,	1,
808	268	808	268	446	213	446	34
0,	1,	0,	1,	0,	0,	0,	0,
771	269	771	269	385	772	385	354
0,	0,	0,	0,	0,	1,	0,	0,
182	506	182	506	861	056	861	784
0,	1,	0,	1,	1,	1,	2,	1,
873	065	873	065	354	354	794	062
				1,	0,	2,	0,
0	0	0	0	261	584	419	461
				1,	1,	3,	0,
0	0	0	0	326	241	126	966
						2,	
0	0	0	0	0	0	076	0
						0,	
0	0	0	0	0	0	876	0
0,	0,	0,	0,	2,	1,	1,	1,
86	881	86	881	804	546	678	168
0,	0,	0,	0,	2,	1,	2,	1,
376	385	376	385	425	431	425	093
0,	0,	0,	0,	3,	1,	3,	1,
779	798	779	798	135	541	135	124
1,	1,	1,	1,				
312	731	312	731	0	0	0	0
1,	1,	1,	1,	1,	1,	1,	0,
223	592	223	592	253	289	253	931
1,	1,	1,	1,	0,	1,	0,	0,
279	757	279	757	542	202	542	877
				1,	1,	1,	0,
0	0	0	0	146	254	146	879
0	0	0	0	0	0	0	0
0,	0,	0,	0,	1,	1,	1,	0,
681	931	681	931	412	158	412	865
0,	0,	0,	0,	1,	0,	1,	0,
299	406	299	406	312	502	312	378
0,	0,	0,	0,	1,	1,	1,	0,
613	844	613	844	389	056	389	784
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
1,	1,	1,	1,	1,	1,	1,	0,
02	009	02	009	253	289	253	931
0,	0,	0,	0,	0,	1,	0,	0,
444	948	444	948	542	202	542	877
0,	0,	0,	0,	1,	1,	1,	0,
828	917	927	958	44	18	44	844
0,	0,			0,	0,	0,	0,
17	406	0	0	515	502	515	378
0,	0,	0	0	1,	1,	1,	0,

345	844			084	056	084	784
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0,	0,	0,	1,		1,		1,
624	897	823	348	0	537	0	236
0,	0,	0,	0,		0,		0,
274	392	36	581	0	659	0	535
0,	0,	0,	0,	1,	1,		1,
34	514	166	237	328	415	0	13
0,	0,	0,	0,	1,			
369	555	369	555	237	0	0	0
0,	0,	0,	0,	1,			
349	537	349	537	296	0	0	0
				1,		2,	
0	0	0	0	811	0	268	0
				1,		2,	
0	0	0	0	661	0	041	0
				1,		2,	
0	0	0	0	854	0	44	0
2,	2,	2,	2,				
991	967	991	967	0	0	0	0
2,	2,	2,	2,	1,	0,	1,	0,
5	496	5	496	546	655	546	491
3,	3,	3,	3,	2,	1,	0,	0,
041	119	041	119	113	052	663	216
				0,	1,	1,	0,
0	0	0	0	685	246	424	44
				1,	1,		
0	0	0	0	631	461	0	0
0	0	0	0	0	0	0	0

D3 Interpretacija rezultata impaktograma na prešama korištenjem signala s peći

Preša 5:

1. trenutak 3 bio je nepovoljan (6.17)

1. trenutak 3 nema nijedan signal peći u području utjecaja.

Zaključak: Na temelju signala peći nakon preše 5 ne može se ustanoviti što je pošlo po krivu u trenutku 3.

Preša 6:

Preša 6 nema nepovoljnih trenutaka (sve je manje od 6.00)

Preša 8:

1. trenutak 2 bio je nepovoljan (6.08)

1. trenutak 2 nema nijedan signal peći u području utjecaja.

Zaključak: Na temelju signala peći nakon preše 8 ne može se ustanoviti što je pošlo po krivu u trenutku 2.

Preša 9

1. trenutak 30 bio je nepovoljan (7.41)

trenutak 30 ima u području utjecaja: s50 crveno i s50 plavo.

Entropija od s50=1.545 u trenutku 28, a od QC=1.569 u trenutku 28 (2.044 vs 1.625 u trenutku 29)

Zaključak:

Signal s50 u trenucima 28 i 29 moguć je uzrok problema.

2. trenutci 39-41 bili su nepovoljni (6.17)

trenutci 39-41 imaju u području utjecaja: s44-s47 plavo, s49 i s51 plavo.

Entropija signala koji se pojavljuju u trenutku 38 je:

s44: 0.917

s45: 0.958

s46: 0.917

s47: 0.958

s49: 1.03

s51: 0.798

Entropija od QC u trenutku 38 je 1.792

Signal s49 ima relativno slabo poklapanje s QC ali najjače od ostalih signala.

Moguće je da se problem očrtava u više peći zbog lošijeg materijala na ulazu, a najveći utjecaj ima signal s peći s49.

Povećani škart u ostalim trenucima nije utjecan od strane ijedne peći.

Preša 10

1. trenutci 18-19 bili su nepovoljni (7.41)

trenutci 18-19 imaju u području utjecaja: s48 plavo, s49 plavo, s50 crveno i plavo, s51 plavo

Entropija signala koji se pojavljuju u trenutku 15 je:

s50: 2.076

Entropija od QC u trenutku 15 je 2.080

Signal s50 je vjerojatan uzrok kvara sa strane peći jer ima vrlo blisku entropiju.

Entropija signala koji se pojavljuju u trenutku 16 je:

s50: 0.876

Entropija od QC u trenutku 16 je 0.878

Signal s50 nastavlja djelovati i uzrokovati kvar.

Entropija signala koji se pojavljuju u trenutku 17 je:

s50: 1.678

Entropija od QC u trenutku 17 je 1.017

Utjecaj signala s50 na kvar se smanjio ali i dalje postoji.

Entropija signala koji se pojavljuju u trenutku 18 je:

s48: 2.425

s49: 1.431

s50: 2.425

s51: 1.093

Entropija od QC u trenutku 18 je 2.109

Sa strane peći, kvar je moguć i dalje na peći s50 ali i na peći s48. Ostale dvije su entropijski predaleko.

U trenutku 19 kvar se više ne očituje na pećima.

2. trenutak 22 bio je nepovoljan (6.03)

U trenutku 22 nema nijednog signala peći u području utjecaja.

3. trenutci 28-30 bili su nepovoljni (6.17).

trenutci 28-30 imaju u području utjecaja: s44-s47 plavo, s49 i s51 plavo i to sve u trenutku 27

Entropija signala koji se pojavljuju u trenutku 27 je:

s44: 0.613

s45: 0.844

s46: 0.613

s47: 0.844

s49: 1.056

s51: 0.784

Entropija od QC u trenutku 27 je 1.792

Iako se utjecaj kvara možda očituje u pećima, signali peći ne upućuju na to da su one uzrok kvara jer su entropije predaleke.

Dodatak E

Analiza entropije signala kontrole kvalitete u KIO Keramika d.o.o [E1]

Signali u postrojenju Kio Keramika odabrani su od proizvođača strojeva tako da prate uzročno- posljedični lanac proizvodnje shodno Ishikawa dijagramu. Pri tome je proizvođač strojeva provodio dugotrajna ispitivanja i podešavanja mjesta mjernih signala u smislu njihove maksimalne informativnosti [149]. Informacijski sadržaj signala moguće je egzaktno utvrditi samo entropijskim mjerama. Provodili smo ispitivanja entropije prema Shannonu, jednodimenzijsku i dvodimenzijsku Carnapovu entropiju.

Entropija podataka signala kontrole kvalitete s dvostupnjevite peći u KIO Keramika d.o.o. postrojenja u Orahovici prikazana je na tablici E.1.

Tablica E1: Izračun entropije za niz od 90 dana na signalima temperature s dvostupnjevite peći postrojenja KIO Keramika d.o.o. u Orahovici

Nazi v kontrolnog	Donja granica temperature, °C	Gornja granica temperature, °C	Shannon entropija, ova bit	1-D Carnapova entropija,	2-D Carnapova entropija,
-------------------------	-------------------------------------	--------------------------------------	-------------------------------------	--------------------------------	--------------------------------

signala				bit/rasponu	bit/rasponu	
1 44	Signa	1106	1166	Nema*	17,0464	5,82848
1 45	Signa	1119	1151	2,89715	20,4124	6,96516
1 46	Signa	1106	1166	Nema	16,8702	5,44023
1 47	Signa	1106	1166	2,9183	19,6232	6,66346
1 48	Signa	1107	1169	Nema	15,7453	5,5408
1 49	Signa	1114	1150	2,74091	18,5061	5,98589
1 50	Signa	1107	1170	Nema	16,0646	5,584
1 51	Signa	1114	1150	2,7879	18,7413	6,5268

* nepostojanje podataka u jednoj ili više klasa podataka

Entropija procesnih podataka sa preša u pogonu KIO Orahovica, Tablica E2

Tablica E2. Izračun entropije za signale 31, signale 10 do 40 uzduž pet preša za proizvodnju keramičkih pločica u pogonu KIO Keramika Orahovica u dnevnoj smjeni kontrole kvalitete proizvoda

Naziv preše	Donja granica podataka	Gornja granica podataka	Shanno nova entropija, bit	1D Carnapova entropija, bit/iznos	2D Carnapova entropija, bit/iznos
Preša 5	-0,1	50,1	Nema*	5,01798	3,29666
Preša 6	0	60,1	Nema	3,16758	3,05867
Preša 8	0	48	Nema	4,59378	3,48107
Preša 9	0	50,1	Nema	3,08708	3,37782
Preša 10	-0,1	47,1	Nema	4,76176	3,30893

*-jedna ili više klasa razdiobe bez podataka

Shanonova entropija pokazala je nedostatke na svakom drugom signalu peći te na svim signalima preša za cijelu seriju snimanja od 90 smjena mjerenja. Za duže mjerne serije moguće bi bilo primijeniti kao alternativnu metodu aproksimativnu entropiju za kraće usporedbe

nizove npr tri podatka ali je za njezino determiniranje potrebne koristiti relativno dugačke serije od nekoliko stotina podataka a sve ovisno o kriteriju sličnosti [E2].

Literatura

[E1] Jović F., Krmpotić D., Jović A. *Process entropy and informational macro-dynamics in a ceramic plant*. MIPRP 2009, 32nd Int. Convention, Proc. Opatija 2009, Conference: Computers in Technical Systems, ed. N. Bogunović, S. Ribarić. pp 50-53.

[E2] Jennifer M. Yentes, Nathaniel Hunt, Kendra K. Schmid, Jeffrey P. Kaipust, Denise McGrath, Nicholas Stergiou: *The appropriate use of approximate entropy and sample entropy with short data sets*, <http://digitalcommons.unomaha.edu/biomechanicsarticles/4>.